

MINISTÉRIO DA EDUCAÇÃO  
UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA MECÂNICA

PREVISÃO DA GERAÇÃO DE ENERGIA ELÉTRICA NO MÉDIO PRAZO PARA O  
ESTADO DO RIO GRANDE DO SUL EMPREGANDO REDES NEURAIS ARTIFICIAIS

por

Marcelo Coletto Rola

Dissertação para obtenção do Título de  
Mestre em Engenharia

Porto Alegre, Fevereiro de 2017

PREVISÃO DA GERAÇÃO DE ENERGIA ELÉTRICA NO MÉDIO PRAZO PARA O  
ESTADO DO RIO GRANDE DO SUL EMPREGANDO REDES NEURAIS ARTIFICIAIS

por

Marcelo Coletto Rola

Engenheiro de Energias Renováveis e Ambiente

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Mecânica, da  
Escola de Engenharia da Universidade Federal do Rio Grande do Sul, como parte dos  
requisitos necessários para a obtenção do Título de

Mestre em Engenharia

Área de Concentração: Energia

Orientador: Prof. Dr. Bardo Ernst Josef Bodmann

Comissão de Avaliação: Aprovada por:

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Adriane Prisco Petry, PROMEC/UFRGS

Prof. Dr. Marco Túllio Menna Barreto de Vilhena, PROMEC/UFRGS

Prof. Dr. Gervásio Annes Degrazia, PPGM/UFSM

Prof. Dr. Jakson Manfredini Vassoler  
Coordenador do PROMEC

Porto Alegre, 13 de Fevereiro de 2017

*Dedico este trabalho a meus pais Carlos e Denise,  
a meu irmão Maurício e a meu amor, Vitória.*

## **AGRADECIMENTOS**

Aos meus pais, Carlos e Denise, pela compreensão e apoio ininterrupto durante toda a minha vida.

A meu irmão, Maurício, pelo companheirismo e incentivo na minha vida acadêmica e profissional.

A Vitória, minha companheira, que assim como eu acredita que a educação de qualidade é essencial para o desenvolvimento do nosso país.

Ao meu orientador, Professor Dr. Bardo J. E. Bodmann, pelos ensinamentos, compreensão, análise e sugestões para a realização deste trabalho.

A todos os meus colegas do curso de pós-graduação, pela amizade durante esta jornada de ensinamentos.

A todos os meus amigos, que de forma direta ou indireta participaram e participam da minha vida.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da bolsa de pesquisa que muito tem auxiliado a realizar nossos estudos no âmbito do setor elétrico nacional e estadual.

## RESUMO

A demanda e, conseqüentemente, a geração de energia elétrica são questões de suma importância para o desenvolvimento econômico e social dos países. Modelos para previsão destes parâmetros no longo e médio prazo são empregados com a finalidade de antever possíveis cenários e propor estratégias para a realização de um planejamento energético adequado. Neste contexto, o presente estudo tem como objetivo realizar a previsão da geração de energia elétrica no estado do Rio Grande do Sul (RS) em um horizonte de médio prazo (um ano), utilizando Redes Neurais Artificiais (RNA's) do tipo *feedforward* com algoritmo de aprendizado supervisionado *backpropagation*. Para o desenvolvimento deste trabalho elaborou-se um script para executar as simulações necessárias, as quais foram realizadas através do software Matlab®. As variáveis de influência selecionadas como entradas do modelo de previsão referem-se à economia (estadual e nacional), ao balanço de energia elétrica e à meteorologia do estado, durante o período de janeiro de 2009 a março de 2016. Para realizar o treinamento da rede neural, adicionou-se a matriz de entrada este conjunto de dados, com frequência mensal, referentes a janeiro de 2009 a março de 2015 e para previsão foram inseridos dados de abril de 2015 a março de 2016. Por fim, depois de realizada a simulação completa da RNA, comparou-se o resultado observado da geração de energia elétrica do estado com o obtido através do modelo de previsão, indicando um erro percentual absoluto médio (MAPE) de 5,86% e um desvio absoluto médio (MAD) de 134,15 MW médio. Os resultados obtidos neste trabalho mostram-se promissores, além de semelhantes aos encontrados na literatura, demonstrando assim confiabilidade e eficácia do método empregado.

Palavras-chave: Geração de Energia Elétrica; Redes Neurais Artificiais; Backpropagation; Modelo de Previsão.

## **ABSTRACT**

The demand and, consequently, the generation of electric power are very important issues for social and economic development of countries. Models to forecast these parameters in long and medium terms are used to anticipate possible sceneries and propose strategies for the energy planning of countries. In this context, the present study aims to forecast the generation of electric energy in Rio Grande do Sul State (RS) in a medium-term horizon (one year) using, Artificial Neural Networks (ANNs) of the feedforward type with algorithm of supervised learning backpropagation. For the development of this work, a script was elaborated in order to execute the necessary simulations, which were carried out through Matlab® software. The selected variables of influence as inputs of forecasting model refer to economy (State and National), to the electric energy balance and to the meteorology State, during the period from January, 2009 to March, 2016. In order to train the neural network, this data set was added to the entrance matrix, with monthly frequency, from January, 2009 to March, 2015 and for prediction, data were inserted from April, 2015 to March, 2016. Finally, after RNA complete simulation, the observed result of the electric power generation of the State was compared with the one obtained through the prediction model, indicating a mean absolute percent error (MAPE) of 5.86% and a mean absolute deviation (MAD) of 134.15 average MW. The obtained results in this work are promising, besides; they are similar to those found in literature, in this way demonstrating the reliability and efficacy of the using method.

**Keywords:** Electric Energy Generation; Artificial Neural Networks; Backpropagation; Forecasting Model.

# ÍNDICE

|          |   |           |
|----------|---|-----------|
| <b>1</b> | <b>INTRODUÇÃO .....</b>   | <b>1</b>  |
| 1.1      | Motivação e Relevância do Trabalho .....  | 1         |
| 1.2      | Objetivos .....   | 4         |
| 1.2.1    | Objetivo Principal .....  | 5         |
| 1.2.2    | Objetivos Específicos .....   | 5         |
| 1.3      | Delimitação do Trabalho .....   | 5         |
| 1.4      | Estrutura da Dissertação .....  | 6         |
| <b>2</b> | <b>MATRIZ ELÉTRICA DO RIO GRANDE DO SUL: CENÁRIO ATUAL .....</b>                                    | <b>8</b>  |
| 2.1.     | Balanço de Energia Elétrica.....  | 11        |
| 2.1.1    | Consumo de energia elétrica.....  | 12        |
| 2.1.2    | Geração de energia elétrica.....  | 16        |
| 2.1.3    | Importação e exportação de energia elétrica (SIN e internacional).....                              | 20        |
| <b>3</b> | <b>REDES NEURAIS ARTIFICIAIS (RNA'S) .....</b>  | <b>23</b> |
| 3.1      | Histórico .....   | 24        |
| 3.2      | Arquitetura de RNA's .....  | 25        |
| 3.3      | Redes Perceptron de Múltiplas Camadas .....   | 26        |
| 3.4      | Processos de Aprendizagem .....   | 29        |
| 3.4.1    | O Algoritmo Backpropagation (Retropropagação) .....   | 35        |
| 3.5      | RNA's Aplicadas para Previsão de Demanda e Geração de Energia Elétrica .....                        | 37        |
| <b>4</b> | <b>METODOLOGIA .....</b>  | <b>41</b> |
| 4.1      | Introdução.....   | 41        |
| 4.2      | Módulo I: Aquisição e classificação dos dados para as entradas da RNA.....                          | 42        |
| 4.3      | Módulo II: Criação, configuração, treinamento, teste e validação da RNA.....                        | 55        |
| 4.4      | Módulo III: Previsão da geração de energia elétrica e processamento dos resultados da previsão..... | 60        |
| <b>5</b> | <b>RESULTADOS E DISCUSSÕES .....</b>  | <b>63</b> |
| <b>6</b> | <b>CONCLUSÕES .....</b>   | <b>74</b> |
| 6.1      | Considerações Futuras.....  | 75        |

|   |           |
|---|-----------|
| <b>REFERÊNCIAS BIBLIOGRÁFICAS .....</b>   | <b>77</b> |
| <b>ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA)</b> |           |
| <b>.....</b>  | <b>83</b> |



## LISTA DE FIGURAS

|             |   |    |
|-------------|---|----|
| Figura 2.1  | Capacidade instalada por estado .....   | 8  |
| Figura 2.2  | Balanco de energia elétrica estadual .....  | 11 |
| Figura 2.3  | Consumo de energia elétrica por setor, [adaptado de BERS, 2015] ...   | 12 |
| Figura 2.4  | Consumo de Energia Elétrica por Município do Rio Grande do Sul<br>em 2014, [BERS, 2015] .....   | 13 |
| Figura 2.5  | Consumo de Energia Elétrica no RS, [EPE, 2016] .....  | 14 |
| Figura 2.6  | Demanda Máxima Mensal do RS (Jan/14 a Jun/15), [adaptada de<br>BERS, 2015] .....  | 16 |
| Figura 2.7  | Geração de energia elétrica (MW médio) por fonte para o estado do<br>RS .....   | 16 |
| Figura 2.8  | Evento precipitação no ano de 2012 (ano hidrológico: entre setembro<br>do ano de referência e outubro do ano anterior), [ANA, 2015] .....                         | 17 |
| Figura 2.9  | Potencial eólico sazonal do RS [Atlas eólico do Rio Grande do Sul,<br>2014] .....   | 18 |
| Figura 2.10 | Importação de energia elétrica do SIN .....   | 20 |
| Figura 2.11 | Exportação de energia elétrica para o SIN .....   | 21 |
| Figura 2.12 | Exportação internacional de energia elétrica .....  | 21 |
| Figura 3.1  | Neurônio de McCulloch e Pitts [adaptado de Guarnieri, 2006] .....   | 24 |
| Figura 3.2  | Representação gráfica de uma RNA do tipo MLP com duas camadas<br>intermediárias, [adaptado de Fiorin et. al., 2011] .....   | 27 |
| Figura 3.3  | Modelo de um neurônio de uma rede MLP, [Adaptado de Haykin,<br>2001] .....  | 27 |
| Figura 3.4  | Exemplos funções de ativação: (a) função degrau; (b) função linear;<br>(c) função logística; (d) função tangente hiperbólica, [adaptado de<br>Haykin, 2001] ..... | 29 |
| Figura 3.5  | Aprendizado supervisionado, [adaptado de Haykin, 2001] .....  | 30 |
| Figura 3.6  | Superfície de erro para dois pesos e exemplos de mínimo global e<br>local, [adaptado de Raizer et al., 2009] .....  | 32 |

|             |   |    |
|-------------|---|----|
| Figura 3.7  | Exemplos de erros em treinamento de uma rede do tipo MLP [Andrade Filho, 2016] .....                                | 34 |
| Figura 4.1  | Carga própria de energia elétrica do estado .....   | 44 |
| Figura 4.2  | ICMS do RS, [adaptado de IPEADATA, 2016] .....  | 46 |
| Figura 4.3  | Inflação IPCA do Brasil, [adaptado de IPEADATA, 2016] .....   | 46 |
| Figura 4.4  | Inflação IGP-M do Brasil, [adaptado de IPEADATA, 2016] .....  | 47 |
| Figura 4.5  | Localização das estações cadastradas pelo INMET, [adaptado de BDMEP, 2016] .....                                    | 50 |
| Figura 4.6  | Velocidade média do vento no RS .....   | 51 |
| Figura 4.7  | Direção média do vento no RS .....  | 51 |
| Figura 4.8  | Precipitação média no RS .....  | 51 |
| Figura 4.9  | Pressão atmosférica média no RS .....   | 52 |
| Figura 4.10 | Temperatura máxima média e temperatura mínima média no RS .....   | 52 |
| Figura 4.11 | Umidade relativa média no RS .....  | 52 |
| Figura 4.12 | Fluxograma do Módulo I .....  | 53 |
| Figura 4.13 | Divisão das variáveis de entrada na RNA .....   | 54 |
| Figura 4.14 | Desempenho do treinamento da RNA em função do n° de neurônios da camada oculta .....                                | 58 |
| Figura 4.15 | Script desenvolvido no Matlab® .....  | 61 |
| Figura 5.1  | Performance dos dados treinamento, teste e validação da RNA .....   | 64 |
| Figura 5.2  | Gráfico de regressão entre a saída e alvo para o conjunto de treinamento da RNA .....                               | 65 |
| Figura 5.3  | Gráfico de regressão entre a saída e alvo para o conjunto de teste da RNA .....                                     | 65 |
| Figura 5.4  | Gráfico de regressão entre a saída e alvo para o conjunto de validação da RNA .....                                 | 66 |
| Figura 5.5  | Gráfico de regressão entre a saída e alvo de todos os conjuntos RNA (todos = treinamento + teste + validação) ..... | 66 |
| Figura 5.6  | Resultado do treinamento da RNA: Geração de energia elétrica em função do tempo .....                               | 67 |
| Figura 5.7  | Histograma de erro absoluto do treinamento da RNA .....   | 68 |

|             |  |    |
|-------------|--|----|
| Figura 5.8  | Histograma de erro relativo percentual do treinamento da RNA ..... | 69 |
| Figura 5.9  | Previsão da RNA: Geração de energia elétrica em função do tempo .. | 70 |
| Figura 5.10 | Erro absoluto da previsão da RNA .....                             | 71 |
| Figura 5.11 | Erro relativo percentual da previsão da RNA .....                  | 71 |

## LISTA DE TABELAS

|            |  |    |
|------------|--|----|
| Tabela 2.1 | Empreendimentos em operação no RS .....  | 9  |
| Tabela 2.2 | Empreendimentos em construção no RS .....  | 10 |
| Tabela 2.3 | Empreendimentos com construção não iniciada no RS .....  | 10 |
| Tabela 2.4 | Demanda máxima de energia elétrica no RS .....   | 15 |
| Tabela 4.1 | Variáveis referentes ao balanço de energia elétrica do RS .....  | 43 |
| Tabela 4.2 | Variáveis econômicas .....   | 45 |
| Tabela 4.3 | Variáveis meteorológicas .....   | 48 |
| Tabela 4.4 | Código de direção do vento .....   | 48 |
| Tabela 4.5 | Cadastro das estações meteorológicas e sua respectiva localização...   | 49 |
| Tabela 4.6 | Desempenho do treinamento da RNA em função do n° de neurônios da camada oculta TRAIGDM .....                 | 57 |
| Tabela 4.7 | Configuração da RNA .....  | 59 |
| Tabela 5.1 | Tabela de erros MAPE e MAD para o treinamento e previsão .....   | 72 |
| Tabela 5.2 | Resultados do erro (MAPE) encontrados na literatura para previsão no setor energético utilizando RNA's ..... | 73 |
| Tabela A.1 | Banco de dados (Matriz de entrada e matriz alvo da RNA) .....  | 83 |

## LISTA DE SIGLAS E ABREVIATURAS

|         |   |
|---------|---|
| a.a.    | Ao ano  |
| ABC     | Artificial Bee Colony                                     |
| AES Sul | Distribuidora Gaúcha de Energia Elétrica                  |
| ANEEL   | Agência Nacional de Energia Elétrica                      |
| ANFIS   | Adaptive Neuro-fuzzy Inference System                     |
| BDMEP   | Banco de Dados Meteorológicos para Ensino e Pesquisa      |
| BEN     | Balanco Energético Nacional                               |
| BERS    | Balanco Energético do Rio Grande do Sul                   |
| BP      | Backpropagation   |
| CEEE    | Companhia Estadual de Energia Elétrica                    |
| CEEE-D  | Companhia Estadual de Distribuição de Energia Elétrica    |
| CGH     | Central Geradora Hidrelétrica                             |
| COS     | Centro de Operações do Sistema                            |
| EOL     | Central Geradora Eólica                                   |
| EPE     | Empresa de Pesquisa Energética                            |
| FFB     | Feedforward Backpropagation                               |
| GB      | Gigabyte  |
| GHz     | Gigahertz   |
| GW      | Gigawatt  |
| IBGE    | Instituto Brasileiro de Geografia e Estatística           |
| ICMS    | Imposto sobre Circulação de Mercadorias e Serviços (ICMS) |
| IGP-M   | Índice Geral de Preços – Mercado                          |
| INCC    | Índice Nacional de Preços da Construção Civil             |
| INMET   | Instituto Nacional de Meteorologia                        |
| INPCA   | Índice Nacional de Preços ao Consumidor Amplo             |
| IPA     | Índice de Preços por Atacado                              |
| IPC     | Índice de Preços ao Consumidor                            |
| IPEA    | Instituto de Pesquisa Econômica Aplicada                  |

|        |  |
|--------|--|
| KNN    | K-ésimo Vizinho mais Próximo ( $K^{\text{th}}$ Nearest Neighbor)                                 |
| kW     | Kilowatt   |
| MAD    | Desvio Absoluto Médio (Mean Absolute Deviation)  |
| MAPE   | Erro Percentual Absoluto Médio (Mean Absolut Percentage Error)                                   |
| MLP    | MultiLayer Perceptron  |
| MME    | Ministério de Minas e Energia  |
| MSE    | Erro Quadrático Médio (Mean Square Error)  |
| MW     | Megawatt   |
| MWh    | Megawatt-hora  |
| NEWAVE | Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo |
| nntool | Pacote de Redes Neurais (Neural Network Toolbox)   |
| OMM    | Organização Meteorológica Mundial  |
| ONS    | Operador Nacional do Sistema Elétrico  |
| PCH    | Pequena Central Hidrelétrica   |
| PDE    | Plano Decenal de Expansão de Energia   |
| PIB    | Produto Interno Bruto  |
| PRE    | Percentage Relative Error  |
| PROMEC | Programa de Pós-Graduação em Engenharia Mecânica   |
| RAM    | Memória de Acesso Randômico (Random Access Memory)   |
| RGE    | Rio Grande Energia   |
| RNA    | Rede Neural Artificial   |
| RS     | Rio Grande do Sul  |
| SC     | Santa Catarina   |
| SEP    | Sistema Elétrico de Potência   |
| SIMCA  | Modelagem Suave Independente por Analogia de Classe (Soft Independent Modeling of Class Analogy) |
| SIN    | Sistema Interligado Nacional   |
| TWh    | Terawatt-hora  |
| UFRGS  | Universidade Federal do Rio Grande do Sul  |
| UFV    | Central Geradora Solar Fotovoltaica  |

|     |                    |
|-----|--------------------|
| UHE | Usina Hidrelétrica |
| UTE | Usina Termelétrica |

## LISTA DE SÍMBOLOS

|                 |  |
|-----------------|--|
| BE              | Balanco de Energia Elétrica, MW médio                    |
| AS              | Saída de Energia Elétrica (SIN e exportação), MW médio   |
| $b_j$           | Bias   |
| CO              | Consumo de Energia Elétrica, MW médio                    |
| $d_j$           | Saída observada (valor alvo)                             |
| $E(t)$          | Função custo   |
| $e_j$           | Erro   |
| EN              | Entrada de Energia Elétrica (SIN e importação), MW médio |
| $j$             | Neurônio   |
| $m$             | Metros   |
| $t$             | Iteração   |
| $w_{ij}$        | Peso sináptico   |
| $x_i$           | Entrada da RNA   |
| $y_j$           | Saída da RNA   |
| $\delta$        | Gradiente local  |
| $\Delta w_{ji}$ | Ajuste do peso sináptico                                 |
| $\theta$        | Limiar   |
| $v_j$           | Nível de atividade interna do neurônio                   |
| $\Sigma$        | Somatório  |
| $\beta$         | Taxa de momentum   |
| $\eta$          | Taxa de aprendizagem                                     |
| $\varphi(.)$    | Função de ativação                                       |



# 1 INTRODUÇÃO

## 1.1 Motivação e Relevância do Trabalho

O Brasil apresenta uma das matrizes energéticas mais diversificadas do mundo, caracterizada por um sistema hidrotérmico e pela predominância de fontes renováveis de energia, as quais segundo o relatório do Balanço Energético Nacional (BEN), 2016, (ano base 2015) representam 75,5% da oferta interna de eletricidade no Brasil (soma dos montantes referentes à produção nacional mais as importações), com destaque para a geração hidráulica que responde por 64% da oferta interna.

Dentro do contexto das energias renováveis, a geração de energia eólica vem ganhado espaço na matriz nacional desde 2006, com a entrada em operação do primeiro parque eólico conectado ao Sistema Interligado Nacional (SIN) e controlado pelo Operador Nacional do Sistema Elétrico (ONS). Este parque eólico, situado em Osório no Rio Grande do Sul (RS), possui 75 aerogeradores de 2 Megawatt (MW), totalizando 150 MW de potência instalada. Desde então, a implantação de parques eólicos no RS apresentou um crescimento significativo devido ao excelente potencial eólico da região, onde no segundo semestre de 2015 a geração eólica ultrapassou a geração térmica na matriz elétrica do estado e atualmente (dezembro de 2016) corresponde a 19% de toda potência gerada no RS.

Em 2015, no Brasil, a oferta interna de energia elétrica por fonte correspondeu a 64% hidráulica (incluindo importação), 12,9% gás natural, 8% de biomassa (incluindo lenha, bagaço de cana, lixo e outras recuperações), 4,8% derivados do petróleo, 4,5% carvão e derivados, 3,5% eólica, 2,4% nuclear e 0,01% solar [BEN, 2016]. Analisando os dados publicados no BEN, 2016, e comparando a matriz energética nacional com outros países, como por exemplo a França, evidencia-se que 74,7% da geração interna francesa é nuclear e não renovável, completamente diferente da realidade brasileira. Desta forma, a diversidade da matriz energética de cada país implica em diferentes estratégias de planejamento energético, uma vez que cada fonte de energia possui suas limitações.

No caso do Brasil, a geração de energia elétrica, oriunda da energia hídrica, eólica, solar e biomassa depende essencialmente das condições climáticas (precipitação, radiação, velocidade do vento, direção do vento predominante, pressão atmosférica,

entre outras), por outro lado as derivadas do gás natural, petróleo, carvão e nuclear dependem muito pouco ou não dependem das condições meteorológicas. Um exemplo envolvendo condições climáticas desfavoráveis e um planejamento energético inadequado ocorreu no país em 2001 e 2002, devido a um baixo volume de chuvas, o complexo gerador de energia elétrica foi incapaz de atender à demanda prevista e desta forma o governo federal teve de implementar o programa de racionamento [Bardelin, 2004]. Ainda conforme o autor torna-se necessário investir adequadamente na geração de energia elétrica quando há um crescimento no consumo de energia, pois caso isso não aconteça, o mercado de energia elétrica pode entrar em déficit de abastecimento.

Dentro do tema da importância das variáveis climáticas no âmbito energético, Andreolli, 2003, descreve que a operação de reservatórios para geração de energia, ou controle de cheias é definido através dos volumes afluentes que são resultantes das chuvas que incidem sobre a bacia, e a utilização de variáveis meteorológicas em modelos de previsão tem por objetivo estimar, por exemplo, o nível dos reservatórios. No contexto da energia eólica, Sombra, 2008, fez o uso de variáveis climáticas aplicados a um modelo atmosférico de mesoescala para prever ventos em um horizonte de curto prazo para aplicações em geração de energia elétrica. Evidencia-se que, em uma matriz energética renovável, os fatores meteorológicos são essenciais para sua quantificação e posteriormente, qualificação.

A economia, outro tema de suma importância dentro da esfera energética, sofre e exerce influência direta e indireta sobre a geração de energia elétrica, além disso, as condições climáticas também possuem uma relação intrínseca com a economia. O Plano Decenal de Expansão de Energia 2024, 2015, prevê que a demanda de energia elétrica no país crescerá no período (2015-2024) a uma taxa média de 4,2% ao ano (a.a.), maior do que o crescimento médio esperado do Produto Interno Bruto (PIB), de 3,2% a.a.. Além disso, estima-se que a demanda de energia elétrica em termos acumulados crescerá 266 Terawatt-hora (TWh). Desta forma, o PIB, um indicador econômico que mede o valor dos bens e serviços que o país produz num período, na agropecuária, indústria e serviços, está diretamente ligado às projeções da demanda de energia elétrica, implicando na elaboração de propostas para a expansão do setor, conforme pode ser observado no Plano Energético do RS, 2016.

Sendo assim, devido à quantidade de fatores de influência, cada país utiliza uma metodologia ou modelo para estimar, com melhor precisão possível, seu setor elétrico,

visando atender a demanda, seja construindo novas usinas, desativando empreendimentos inviáveis, importando energia ou até mesmo exportando. O modelo empregado no Brasil denomina-se NEWAVE (Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo), baseado em programação dinâmica dual estocástica. Este modelo é responsável pelo planejamento da expansão, planejamento da operação, comercialização, definição e cálculo da garantia física e da energia assegurada de empreendimentos de geração e elaboração de diretrizes para os leilões de energia [Eletrobras, 2016].

Dentro do contexto do setor elétrico, a procura por modelos de previsão de curto, médio e longo prazo que visam suprir o consumo, demanda, abastecimento e prever a geração de energia elétrica de diferentes fontes, têm estimulado muitos pesquisadores [Rahman e Hazim, 1993; Charytoniuk e Chen 2000; Beccali et al., 2004; Yap et al., 2006; Romera et al., 2007; Mamlook et al., 2009; Bashir e Hawary, 2009; Melo, 2012; Tidre et. Al., 2013 e Günay, 2016]. Estes modelos, em sua grande maioria, tem o objetivo de tentar prever, com maior fidelidade possível, futuros acontecimentos baseados em ocorrências passadas ou em possíveis cenários elaborados por especialistas no assunto.

Segundo Oliveira e Mendiondo, 2014, os primeiros modelos de previsão desenvolvidos baseavam-se em ferramentas estatísticas, como por exemplo, o método da regressão linear e séries temporais, os quais ainda hoje são amplamente utilizados. Devido à necessidade de solucionar problemas cada vez mais complexos e aliados ao avanço da tecnologia computacional, outros métodos foram desenvolvidos e empregados, tais como Redes Neurais Artificiais (RNA's), Algoritmos Genéticos, Lógica Fuzzy, entre outros. Considerando horizontes de previsão de médio, longo e curto prazo, a aplicação de redes neurais mostrou-se uma boa alternativa para estimar comportamentos do setor energético, devido à produção de resultados interessantes para o Sistema Elétrico de Potência (SEP) [Andrade, 2010].

Conforme Haykin, 2004, uma RNA é um sistema de processamento massivamente paralelo, composto por unidades simples com capacidade natural de armazenar conhecimento e disponibilizá-lo para uso futuro. Existe um grande número de técnicas e configurações possíveis para uma RNA e uma arquitetura muito utilizada na literatura é a *MultiLayer Perceptron* (Perceptrons de múltiplas camadas - MLP). Esta arquitetura é formada por múltiplas camadas (entrada, intermediárias e saída) e por

unidades de processamento interligadas conhecidas como neurônios (ou nós), e tem a tendência natural para armazenar conhecimento experimental e torná-lo disponível para uso futuro [Pádua et. al, 2007]. Para a rede adquirir conhecimento experimental, ela baseia-se na função de aprendizado ou treinamento, como por exemplo, o método *Backpropagation*, que realiza ajustes iterativos nos pesos sinápticos da rede como o objetivo de minimizar as diferenças entre o valor de saída produzido e desejado [Haykin, 2001].

As previsões empregando RNA's, em sua grande maioria, utilizam uma matriz de entrada contendo informações que exercem influência sobre um dado desejado, por exemplo, um conjunto de dados meteorológicos contendo a velocidade do vento média, direção do vento predominante, pressão atmosférica, radiação, umidade relativa do ar e temperatura, exercem influência sobre a precipitação. Considerando uma rede neural do tipo MLP, com algoritmo *backpropagation* a mesma analisará o comportamento dos dados da matriz de entrada em relação ao dado de saída, fazendo com que a rede aprenda através de exemplos em um processo iterativo de ajustes dos pesos das conexões, no qual ao final do processo terá adquirido o conhecimento necessário sobre os respectivos dados [Pádua et. al, 2007].

Diante do que se discutiu até o presente momento e considerando a importância e relevância de um planejamento elétrico adequado, o qual se concretiza através de modelos e técnicas de previsão, que empregam inúmeras variáveis de influência, o presente trabalho tem como propósito prever a geração de energia elétrica no estado do Rio Grande do Sul, no horizonte de médio prazo (um ano), levando em consideração dados do balanço de energia elétrica e meteorológicos do estado e informações referentes à economia estadual e nacional, empregando uma RNA do tipo MLP com algoritmo de aprendizado *backpropagation*.

Ressalta-se que através de buscas na literatura, não foi encontrado nenhum estudo semelhante empregando o conjunto de variáveis citados anteriormente com a técnica das RNA's para prever a geração de energia elétrica no RS, sendo esta, a principal motivação para a elaboração desta dissertação.

## 1.2 Objetivos

Nesta seção serão apresentados o objetivo principal e os objetivos específicos deste trabalho.

### 1.2.1 Objetivo Principal

Este estudo tem como propósito realizar a previsão da geração de energia elétrica no estado do Rio Grande do Sul, no horizonte de médio prazo (de abril de 2015 a março de 2016), levando em consideração dados do balanço de energia elétrica e meteorológicos do estado e informações referentes à economia estadual e nacional, empregando uma RNA do tipo MLP com algoritmo de aprendizado *backpropagation*.

### 1.2.2 Objetivos Específicos

- Elaborar e disponibilizar um banco de dados, o qual contenha informações referentes ao balanço mensal de energia elétrica, dados meteorológicos e econômicos do estado do RS, além de dados econômicos do país;
- Identificar e selecionar, durante a configuração e criação da RNA, o número de neurônios da camada intermediária da RNA baseado na busca do menor erro quadrático médio (*Mean Square Error* - MSE);
- Apresentar graficamente o comportamento de convergência dos dados de treinamento, teste e validação da RNA ao longo do treinamento;
- Demonstrar a relação (equação de regressão linear e coeficiente de correlação) entre os resultados previstos (simulado) e os observados para o conjunto de dados de treinamento, validação e teste;
- Realizar a comparação dos resultados obtidos com estudos científicos presentes na literatura, no âmbito da previsão de energia elétrica (consumo, demanda e geração);

### 1.3 Delimitação do Trabalho

O presente trabalho possui inicialmente uma delimitação espacial, ou seja, o local onde o estudo acontece, sendo este definido ao estado do RS. Optou-se por um estado que apresentasse mais de duas fontes de geração de energia, sendo pelo menos

uma delas não renovável e que mais de 50% da matriz elétrica estadual fosse renovável. Foram definidas estas condições com o intuito de realizar um estudo em menor escala e que fosse condizente com as condições nacionais em termos da matriz elétrica. Além disso, escolheu-se um estado e não o país devido ao fato da quantidade e disponibilidade de informações sobre o mesmo. Segundo Prodanov e Freitas, 2013, o parâmetro espacial selecionado implicará nos resultados obtidos e consequentemente nas conclusões de um estudo.

O segundo critério refere-se à delimitação temporal, a qual descreve o período e frequência em que o estudo ocorre. Desta maneira, utilizarem-se dados referentes ao balanço de energia elétrica e meteorológicos do estado, além de dados econômicos do RS e do Brasil, no período entre janeiro de 2009 a março de 2016 com frequência mensal. A justificativa para a escolha do intervalo e frequência do estudo limitou-se pela acessibilidade dos dados, visto que os mesmos, como a determinada especificidade não foram encontrados via meios de pesquisa convencionais (internet, livro, revistas entre outros). Entretanto, solicitou-se a Companhia Estadual de Energia Elétrica (CEEE), responsável pelo relatório do Balanço Energético do Rio Grande do Sul (BERS), os dados mensais entre janeiro de 2009 a março de 2016 referentes ao balanço de energia elétrica do estado, os quais foram disponibilizados.

#### **1.4 Estrutura da Dissertação**

Visando uma melhor compreensão da estrutura desta dissertação, dividiu-se a mesma em seis capítulos, os quais serão descritos a seguir:

##### **- Capítulo 1: Introdução**

Este capítulo apresentou uma abordagem inicial sobre os temas referentes ao presente estudo, destacando as justificativas e motivações para a realização do mesmo. Posteriormente descreveram-se o objetivo principal e específicos desta dissertação, além da delimitação do trabalho.

##### **- Capítulo 2: Matriz Elétrica do Rio Grande do Sul: Cenário Atual**

No capítulo 2 serão evidenciados assuntos referentes à capacidade instalada do estado, empreendimentos em operação, em construção e construção não iniciada,

classificação do tipo de empreendimento, bem como, uma análise do balanço de energia elétrica estadual. Apresentar-se-ão os dados mais recentes referentes à geração, consumo, demanda, importação e exportação de energia elétrica do RS.

#### - Capítulo 3: Redes Neurais Artificiais (RNA's)

No capítulo 3 serão discutidos os principais conceitos sobre redes neurais artificiais, tais como, uma breve introdução, histórico, arquitetura das redes, redes perceptron de múltiplas camadas e algoritmos de aprendizagem (*Backpropagation*). Ao final do capítulo serão apresentados alguns trabalhos encontrados na literatura que empregam RNA's para realizar previsões na área de energia elétrica (geração, consumo e demanda).

#### - Capítulo 4: Metodologia

Neste capítulo apresentar-se-á a elaboração da metodologia, bem como sua divisão em três módulos distintos. O primeiro módulo descreverá a aquisição e classificação dos dados para as entradas da RNA, o segundo módulo tratará da criação, configuração, treinamento, teste e validação da RNA, e por fim, o terceiro módulo diz respeito à previsão selecionada e processamento dos resultados.

#### - Capítulo 5: Resultados e Discussões

No capítulo 5, demonstrar-se-ão os resultados obtidos através da aplicação da metodologia elaborada no capítulo anterior. Serão comparados os resultados previstos (simulados) e observados através da forma gráfica para os dados de treinamento e previsão da RNA. Serão calculados os erros da previsão (Erro Absoluto, Erro Percentual Absoluto Médio, Desvio Absoluto Médio e Erro Relativo Percentual) e os mesmos serão comparados com os encontrados na literatura.

#### - Capítulo 6: Conclusões

No capítulo final, serão realizadas as conclusões a respeito do estudo realizado, indicando se o modelo apresentou resultados satisfatórios e se a RNA conseguiu captar padrões de reconhecimento adequados para efetuar a previsão, além disso, propostas futuras com novas abordagens de pesquisa serão evidenciadas.

## 2 MATRIZ ELÉTRICA DO RIO GRANDE DO SUL: CENÁRIO ATUAL

A Agência Nacional de Energia Elétrica (ANEEL) registrou no estado do Rio Grande do Sul, em dezembro de 2016, 320 empreendimentos em operação, gerando 9.721.372 kilowatt (kW) de potência, sendo previsto para os próximos anos um acréscimo de 2.439.650 kW na capacidade de geração do estado, proveniente dos 16 empreendimentos atualmente em construção e mais 22 com construção não iniciada [ANEEL, 2016a]. Ainda segundo a agência, o estado corresponde a 6,44% da capacidade instalada do país, ficando apenas atrás dos estados de São Paulo, Paraná, Minas Gerais e Pará. A Figura 2.1 ilustra a capacidade instalada em porcentagem para todos os estados do território brasileiro.




Figura 2.1 – Capacidade instalada por estado.

A matriz da geração de energia elétrica do RS é composta por quatro tipos de fontes de energia: hídrica, térmica, eólica e atualmente a solar. No estado, em setembro de 2016, foi registrada a primeira Central Geradora Solar Fotovoltaica (UFV) na cidade



de Santa Cruz do Sul, com potência instalada de aproximadamente 44 kW [ANEEL, 2016b].

Os empreendimentos derivados da fonte hídrica são classificados conforme a ANEEL em Central Geradora Hidrelétrica (CGH) com potência instalada menor ou igual a 1 MW, Pequena Central Hidrelétrica (PCH) com potência instalada entre 1 e 30 MW e Usina Hidrelétrica (UHE) com potência instalada superior a 30 MW. Já os oriundos da fonte eólica recebem a denominação de Central Geradora Eólica (EOL) e os da fonte térmica são chamados de Usina Termelétrica (UTE).

Dentre os empreendimentos em operação no estado aproximadamente 55% fazem uso da energia hídrica, com predominância para as UHE (49,52%), seguidos de usinas termelétricas e eólicas, conforme demonstra-se na Tabela 2.1.

Tabela 2.1 – Empreendimentos em operação no RS

| <b>Tipo</b>  | <b>Quantidade</b> | <b>Potência (kW)</b> | <b>%</b>   |
|--------------|-------------------|----------------------|------------|
| CGH          | 51                | 35.185               | 0,36       |
| EOL          | 71                | 1.923.367            | 19,78      |
| PCH          | 53                | 591.493              | 6,08       |
| UFV          | 1                 | 44                   | 0          |
| UHE          | 18                | 4.813.553            | 49,52      |
| UTE          | 126               | 2.357.730            | 24,25      |
| <b>Total</b> | <b>320</b>        | <b>9.721.372</b>     | <b>100</b> |

Fonte: adaptada de ANEEL, 2016a.

Por outro lado, conforme a agência, em um horizonte de no máximo 5 anos, serão adicionados 562, 5 MW na capacidade de geração provindos, quase que em sua grande maioria, de usinas termelétricas, sendo que uma delas está em fase de construção na cidade de Candiota e possuirá 340 MW de potência instalada. Segundo Gomes et al., 2003, nesta região encontra-se a maior mina de carvão mineral a céu aberto do Brasil, administrada pela Companhia Riograndense de Mineração (CRM), e devido a esta abundância a região torna-se atrativa para a inserção de UTE's. Além disso, 13 empreendimentos eólicos serão instalados na região litorânea do estado, sendo 3 no município de Rio Grande e 10 no município de Santa Vitória do Palmar, totalizando

uma potência instalada de 205,5 MW [ANEEL, 2016a]. Na Tabela 2.2 evidenciam-se os empreendimentos em construção no RS.

Tabela 2.2 – Empreendimentos em construção no RS

| <b>Tipo</b>  | <b>Quantidade</b> | <b>Potência (kW)</b> | <b>%</b>   |
|--------------|-------------------|----------------------|------------|
| EOL          | 13                | 205.500              | 36,53      |
| PCH          | 1                 | 9.000                | 1,6        |
| UTE          | 2                 | 348.000              | 61,87      |
| <b>Total</b> | <b>16</b>         | <b>562.500</b>       | <b>100</b> |

Fonte: adaptada de ANEEL, 2016a.

Empreendimentos que já possuem registro na ANEEL, porém ainda não tiveram sua construção iniciada, têm a perspectiva de uma potência instalada em torno de 1880 MW, liderados novamente pelas UTE's. Nestes empreendimentos, ainda com construção não iniciada, merece destaque a Termelétrica Rio Grande S.A., situada na cidade Rio Grande e que utilizará gás natural como combustível, possuindo uma capacidade instalada de 1238 MW. A Tabela 2.3 descreve que tipo de empreendimentos não tiveram sua construção iniciada.

Tabela 2.3 – Empreendimentos com construção não iniciada no RS

| <b>Tipo</b>  | <b>Quantidade</b> | <b>Potência (kW)</b> | <b>%</b>   |
|--------------|-------------------|----------------------|------------|
| CGH          | 1                 | 540                  | 0,03       |
| EOL          | 2                 | 20.400               | 1,09       |
| PCH          | 14                | 215.870              | 11,5       |
| UHE          | 1                 | 40.540               | 2,16       |
| UTE          | 4                 | 1.599.800            | 85,22      |
| <b>Total</b> | <b>22</b>         | <b>1.877.150</b>     | <b>100</b> |

Fonte: adaptada de ANEEL, 2016a.

Os dados apresentados neste subcapítulo, até o presente momento, descrevem os registros atualizados (dezembro de 2016) da capacidade instalada dos empreendimentos, separados por tipo, quantidade e potência, além de evidenciar qual a atual situação do

mesmo (em operação, construção ou construção não iniciada). Na sequência apresentar-se-ão informações referentes ao balanço de energia elétrica do estado, tais como: consumo, geração, importação e exportação (internacional e do SIN).

## 2.1. Balanço de Energia Elétrica

Apesar do sistema elétrico brasileiro ser interligado, cada estado possui sua respectiva parcela de geração e consumo de energia elétrica, além disso, alguns estados em regiões de divisa internacional, como por exemplo o RS, importam energia elétrica para o sistema ou exportam a energia elétrica gerada no SIN. É importante destacar que, as informações apresentadas nesta seção referentes a geração de energia elétrica, exportação e importação (SIN e internacional) do RS, foram solicitadas para a CEEE e disponibilizadas pela Diretoria de Planejamento e Projetos Especiais do grupo, os quais possuem um periodicidade mensal entre janeiro de 2009 a março de 2016.

O estado faz parte do SIN, porém considerando o mesmo como um elemento isolado do SIN, o balanço de energia elétrica pode ser ilustrado de uma forma mais simplificada através da Figura 2.2.




Figura 2.2 – Balanço de energia elétrica estadual.

Através do cálculo do balanço de energia elétrica torna-se possível analisar se o estado consegue produzir toda a energia elétrica que consome (autossuficiente), ou não. A Equação (2.1) apresenta o respectivo cálculo do balanço de energia elétrica, considerando como unidade de medida o MW médio:

$$BE = EN - SA + GE - CO \quad (2.1)$$

onde, BE refere-se ao balanço de energia elétrica, EN a entrada de energia elétrica (SIN e importação), AS a saída de energia elétrica (SIN e exportação), GE a geração de energia elétrica e CO ao consumo de energia elétrica.

Conforme o Ministério de Minas e Energia (MME), 2016, o intercâmbio de energia elétrica (importação e exportação) entre o Brasil, a Argentina e o Uruguai é um processo normal entre os países, na qual esta “transferência” se dá através do estado do RS. Analisando a Figura 2.2, observa-se que a entrada de energia elétrica no estado diz respeito à importação internacional e a importação do SIN e as saídas correspondem à exportação internacional e a exportação ao SIN. Na sequência apresentar-se-á individualmente dados referentes ao consumo, a geração e as importações e exportações de energia elétrica no RS.

### 2.1.1 Consumo de energia elétrica

O consumo de energia elétrica no RS em 2014 foi liderado pelo setor industrial, seguido pelo setor residencial, comercial, rural e outros (serviço público e transportes) [BERS, 2015]. Ainda conforme os dados do último balanço, que tem como ano base 2014, foram consideradas no estudo somente as três maiores concessionárias de energia elétrica do estado, sendo elas: CEEE-D (Companhia Estadual de Distribuição de Energia Elétrica), AES Sul (Distribuidora Gaúcha de Energia Elétrica) e Rio Grande Energia (RGE). A Figura 2.3 ilustra o consumo de energia elétrica por setor.




Figura 2.3 - Consumo de energia elétrica por setor, [adaptado de BERS, 2015].






Figura 2.5 - Consumo de Energia Elétrica no RS, [adaptado de EPE, 2016].

Observa-se na Figura 2.5 que durante os dois primeiros meses de 2014 houve o maior consumo de energia elétrica já registrado. Conforme o Centro de Operações do Sistema (COS) do Grupo CEEE, no dia 06 de fevereiro de 2014, às 13h52min, a companhia registrou a demanda instantânea de 6.902 MW, anteriormente em 23 de janeiro de 2014, o sistema alcançou 6.765 MW às 14h32min [CEEE, 2014]. Ainda segundo a companhia, os fatores que em conjunto vêm provocando esse aumento no consumo são as altas temperaturas e as grandes cargas derivadas do uso intensivo dos equipamentos de refrigeração, aliado ao crescimento da produção industrial.

Ressalta-se que, o consumo é a energia consumida em um período determinado, geralmente mensal, e a demanda é o consumo instantâneo requisitado pelo sistema. A Tabela 2.4 apresenta o registro das demandas máximas de energia elétrica no RS entre os anos 2000 e 2014, descrevendo as respectivas datas, horários e temperaturas.

Tabela 2.4 – Demanda máxima de energia elétrica no RS

| <b>Data</b> | <b>Horário</b> | <b>Demanda máxima<br/>(MW)</b> | <b>Temperatura<br/>(°C)</b> |
|-------------|----------------|--------------------------------|-----------------------------|
| 13/12/2000  | 14:31          | 3846                           | 36,0                        |
| 14/03/2001  | 14:08          | 3945                           | 35,1                        |
| 04/03/2002  | 16:12          | 3957                           | 36,4                        |
| 27/02/2003  | 14:50          | 4075                           | 37,5                        |
| 14/04/2004  | 18:59          | 4216                           | 30,8                        |
| 07/04/2005  | 19:03          | 4367                           | 32,6                        |
| 14/12/2006  | 15:08          | 4517                           | 37,2                        |
| 10/12/2007  | 14:41          | 4697                           | 34,8                        |
| 10/01/2008  | 14:31          | 4823                           | 35,6                        |
| 10/02/2009  | 15:28          | 4814                           | 33,0                        |
| 12/02/2010  | 14:07          | 5268                           | 34,8                        |
| 25/02/2011  | 14:22          | 5547                           | 31,4                        |
| 16/02/2012  | 14:43          | 5961                           | 35,4                        |
| 01/02/2013  | 14:28          | 6280                           | 37,1                        |
| 06/02/2014  | 13:52          | 6902                           | 38,2                        |

Fonte: adaptada de CEEE, 2014.

Nos dados da Tabela 2.4 destaca-se que a grande maioria dos registros máximos de demanda de energia elétrica ocorreu durante a estação de verão (entre dezembro e março), demonstrando que estes valores evidenciaram uma relação direta com a elevação de temperatura. Segundo de Mello et al., 2008, em regiões de clima quente, as temperaturas mais elevadas implicam em um maior consumo devido à necessidade de refrigeração, o que justificou a crise brasileira de energia elétrica em 2001-2002.

A Figura 2.6 ilustra a demanda máxima mensal do sistema de transmissão de energia elétrica entre o período de janeiro de 2014 a junho de 2015, ressaltando os maiores consumos de energia no verão.




Figura 2.6 - Demanda Máxima Mensal do RS (Jan/14 a Jun/15), [GRUPO CEE].

### 2.1.2 Geração de energia elétrica

A geração de energia elétrica no estado origina-se basicamente de três fontes: hídrica ou hidráulica, térmica e eólica, conforme demonstrados nas Tabelas 2.1, 2.2 e 2.3. Sendo assim, cada fonte contribui com a sua respectiva parcela, na qual a fonte hídrica é responsável por liderar o cenário da geração de energia elétrica. Esta afirmação pode ser observada na Figura 2.7, através dos dados disponibilizados pela Diretoria de Planejamento e Projetos Especiais do grupo CEEE.




Figura 2.7 - Geração de energia elétrica (MW médio) por fonte para o estado do RS.



Destaca-se na Figura 2.7 um decréscimo na geração de energia elétrica derivada da fonte hídrica no ano de 2012, segundo a Agência Nacional das Águas (ANA), 2015, uma das justificativas refere-se a uma situação crítica de seca no sul do Brasil, principalmente na região do baixo rio Uruguai, apresentando um evento classificado como muito ou extremamente seco em mais de 90% das estações. Além disso, a agência destaca outro motivo para este acontecimento na região sul do Brasil, sendo este devido à grande demanda de água para irrigação (arroz inundado), na qual muitos rios apresentaram níveis críticos.

No ano de 2012, o fenômeno climático não afetou somente o estado, mas também atingiu significativamente as regiões nordeste e sudeste do país, afetando setores como abastecimento de água para consumo, irrigação e energia hidrelétrica (principal matriz energética do país) [ANA, 2015].

Na Figura 2.8, apresenta-se o evento de precipitação para o ano de 2012, no qual as cores quentes representam eventos de seca, as frias (tons de azuis) eventos de cheia e cores intermediárias representam condições de normalidade dos eventos de precipitação.

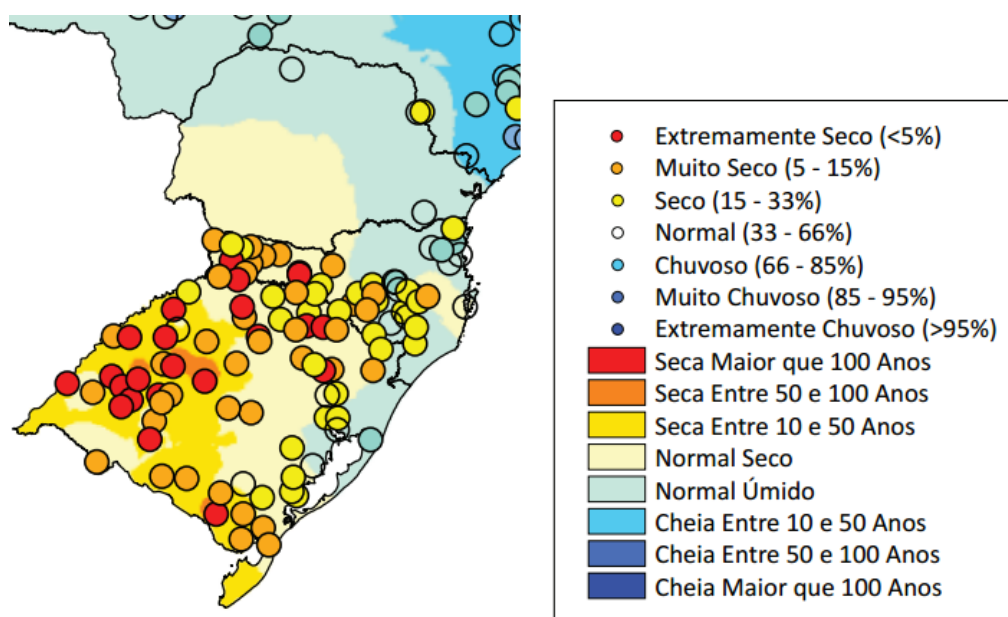


Figura 2.8 – Evento precipitação no ano de 2012 (ano hidrológico: entre setembro do ano de referência e outubro do ano anterior), [ANA, 2015].

Conforme descrito na introdução deste estudo, a energia elétrica proveniente da energia eólica entrou na matriz elétrica do estado em 2006 e desde então vem

aumentando os níveis de capacidade instalada, número de empreendimentos e consequentemente geração. Isto se deve pelo expressivo potencial eólico do estado, principalmente na região litorânea, conforme apresenta o Atlas Eólico do Rio Grande do Sul, 2014, evidenciando os respectivos potenciais eólicos para as alturas de 100 e 150 metros (m).

Além da energia eólica influenciar diretamente na matriz elétrica do estado, ela afeta positivamente a economia, proporcionando condições atrativas para a instalação de parques eólicos, empresas fabricantes da cadeia produtiva, mão de obra qualificada, gerando emprego e renda para o estado [Atlas Eólico do Rio Grande do Sul, 2014].

Segundo os dados do atlas, o potencial eólico, em terra firme (*onshore*), é de 103 GW para a altura 100 m e 245 GW para a altura de 150 m, porém sobre lagoas e oceano (*offshore*) o potencial é de 34 GW e 80 GW (laminas d'água de até 50 m), respectivamente. A Figura 2.9 ilustra o potencial eólico sazonal do RS a 100 metros (m) de altura.

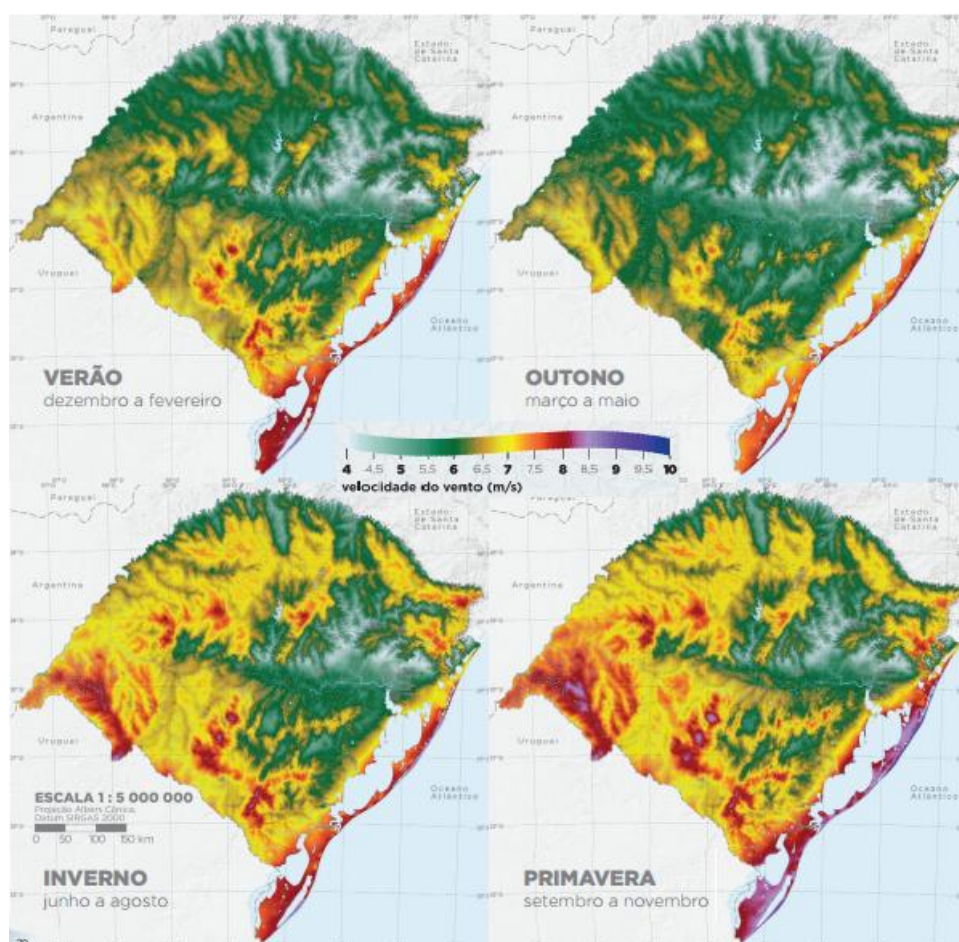


Figura 2.9 – Potencial eólico sazonal do RS [Atlas Eólico do Rio Grande do Sul, 2014].

Observando a Figura 2.7, a qual descreve a geração de energia elétrica por fonte para o estado do RS, percebe-se que a geração eólica registrou um aumento significativo (ultrapassando a geração térmica), devido ao fato da inserção de mais parques em operação, principalmente os situados nas cidades de Sant'Ana do Livramento, Rio Grande, Santa Vitória do Palmar e Chuí [BERS, 2015].

A geração de energia elétrica via termelétricas no estado corresponde atualmente 24,25% (vide Tabela 2.1), totalizando 126 empreendimentos. Galvão e Bermann, 2015, citam sobre a dependência do sistema elétrico brasileiro em relação à geração hidrelétrica, porém a redução dos níveis de precipitação, com a consequente diminuição das afluições naturais nos reservatórios, acarreta na necessidade de recorrer à geração termelétrica.

No ano de 2012 (vide Figura 2.7), devido ao baixo índice de chuvas e a potência eólica instalada ainda em crescimento, fez-se necessário o aumento na capacidade de geração termelétrica, visando suprir não somente a demanda do estado, mas também do SIN. Este mesmo comportamento foi registrado durante os primeiros meses de 2015, no qual vale se destacar novamente que é nos meses de temperaturas mais elevadas que o consumo de energia elétrica aumenta, e desta forma, a geração termelétrica entra em atividade para realizar esta compensação.

Desta maneira, quando as condições meteorológicas não são favoráveis a geração de energia hidrelétrica ou eólica, faz-se a necessidade do uso da energia termelétrica. No estado, os combustíveis utilizados nestas usinas são o carvão mineral, óleo combustível, gás natural, óleo diesel, resíduos florestais, casca de arroz, biogás, licor negro, etanol e outros energéticos do petróleo [ANEEL, 2016a].

As usinas termelétricas possuem inúmeros custos de geração em consequência da tecnologia empregada e ao combustível [da Silva et al., 2016]. Os autores descrevem que em empreendimentos do gênero, o tipo de tecnologia e combustível é escolhido através de critérios econômicos (custo de geração), acesso ao combustível (localização e segurança) e aspectos ambientais. Além do mais, os autores apresentam em seu artigo os custos de produção de eletricidade para diferentes fontes de energia no país durante o período de 2005 a 2015, no qual o preço total (US\$/MWh) para as fontes de usinas termelétricas foi no mínimo o dobro comparado as fontes hídricas e eólicas.

### 2.1.3 Importação e exportação de energia elétrica (SIN e internacional)

A importação de energia elétrica no estado via SIN, apresenta-se registrada na Figura 2.10, lembrando que estes dados foram disponibilizados pela Diretoria de Planejamento e Projetos Especiais do grupo CEEE.




Figura 2.10 – Importação de energia elétrica do SIN.

A importação de energia elétrica do SIN tem por objetivo suprir a demanda do estado e exportar o restante, atendendo os contratos firmados com o Uruguai e a Argentina. Durante o período de janeiro de 2009 a março de 2016 (87 meses), a importação internacional de energia, feita através do RS, ocorreu somente em três meses, sendo eles, outubro, novembro e dezembro de 2009, importando 9,21, 1,82 e 1,72 MW médio, respectivamente. O registro destes dados pode ser verificado ao fim desta dissertação no Anexo A.

Na Figura 2.11 apresenta-se a exportação de energia elétrica do estado para o SIN, no qual observa-se que em 2012 ocorreu a menor transferência anual para o sistema.




Figura 2.11 – Exportação de energia elétrica para o SIN.

O decréscimo na exportação de energia elétrica para o sistema interligado em 2012 ocorreu devido à falta de precipitação aliado as altas temperaturas registradas e o consumo elevado, conforme comentando anteriormente, [ANA, 2015 e CEEE, 2014] e destacado nas Figuras 2.7 e 2.8. Além do mais, ressalta-se que nos meses de verão a exportação para o SIN diminui, também devido ao aumento do consumo de energia elétrica em consequência das altas temperaturas (vide Tab 2.4 e Fig 2.5). Os dados referentes à exportação internacional de energia elétrica via o estado do RS estão apresentados na Figura 2.12.




Figura 2.12 – Exportação internacional de energia elétrica.

Analisando a Figura 2.12, evidencia-se que os valores mais elevados da exportação internacional de energia elétrica ocorreram durante os anos de 2011 e 2012. Um dos motivos plausíveis considerado pelo autor deste trabalho diz respeito aos mesmos do RS (temperaturas elevadas, consumo intensificado e falta de chuvas), pois a Argentina e o Uruguai além de possuírem divisas territoriais com o estado, ainda dividem um dos rios com maior potencial hídrico para geração de energia elétrica, o rio Uruguai. Neste rio, estão em operação as UHE's de Itá e Foz do Chapecó, ambas na divisa entre o RS e Santa Catarina (SC) com potência instalada de 1450 MW e 855 MW respectivamente [ANEELa, 2016]. Destaca-se que estes dois empreendimentos são os que possuem a maior potência instalada na sua categoria (aproximadamente 50% de todas UHE's), demonstrando o alto potencial hídrico deste rio e a importante influência que exerce na matriz elétrica estadual (em torno de 25% de toda potência instalada no RS).

Através do conjunto de dados apresentados nesta seção (geração, consumo, importações e exportações) torna-se possível realizar o balanço de energia elétrica no RS (vide Equação (2.1)). Além disso, observou-se a influência das condições climáticas na matriz de geração, na qual, caso seja desfavorável, o acionamento das termelétricas torna-se necessário, aumentando o custo de geração.

Informações deste tipo são geralmente empregadas em modelos de previsão, pois a partir delas pode ser possível extrair comportamentos, os quais baseiam-se principalmente em condições meteorológicas e econômicas do local a ser estudado (estado ou país, por exemplo). Estas afirmações serão constatadas no capítulo seguinte, no qual na seção 3.5 apresentar-se-ão alguns trabalhos encontrados na literatura que utilizam estes tipos de variáveis em seus modelos de previsão.

### 3 REDES NEURAIS ARTIFICIAIS (RNA'S)

As RNA's funcionam de forma a representar o funcionamento do cérebro humano de uma maneira simplificada, sendo capazes de solucionar problemas complexos empregando os conhecimentos adquiridos a partir do ambiente [Haykin, 2001]. Resumidamente, as RNA's adquirem e armazenam conhecimento a partir de exemplos, no qual esta “inteligência” adquirida é empregada para resolver diversos problemas, entre eles o reconhecimento de padrões, previsão, categorização, classificação e diversas outras aplicações.

Os neurônios, um dos mais importantes elementos de uma RNA, são unidades de processamento simples que compõe a mesma e tem por objetivo computar funções matemáticas a partir de entradas apresentadas, sendo que estas funções são, na grande maioria das vezes, não lineares [Haykin, 2004]. Segundo o autor, a disposição paralela dos neurônios constituem camadas, as quais são interligadas com uma camada vizinha através de conexões e são associadas a pesos. Esses pesos recebem o nome de pesos sinápticos em consequência das múltiplas ligações dos neurônios no cérebro humano, nas quais estas conexões entre unidades de uma rede neural são chamadas sinapses. Estes pesos sinápticos tem a função de armazenar o conhecimento obtido pelo modelo e também servem para avaliar a entrada recebida por cada neurônio da rede [de Pádua, 2007].

Em uma RNA, existe uma etapa onde os pesos sinápticos são calibrados de forma a proporcionar à rede a capacidade de representar o problema, a esta etapa dá-se o nome de fase de aprendizagem. Desta forma, uma vez que a rede tenha sido treinada e a mesma tenha aprendido, fixa-se os pesos e a emprega como um modelo, apresentando novos conjuntos de entradas para estimar futuras saídas.

Este capítulo tem por objetivo apresentar os tópicos principais sobre RNA's, iniciando por um breve histórico, arquiteturas (topologias), processos de aprendizagem, características gerais e aplicações.

É de suma importância evidenciar que existem diversas topologias, configurações e detalhes envolvidos no contexto das RNA's, porém neste trabalho será dado enfoque somente nos conceitos mais importantes, destacando os conhecimentos necessários à compreensão do mesmo. Para uma descrição detalhada sobre a temática de redes neurais, aconselha-se a leitura de Haykin, 2001, e Braga et al., 2007.

### 3.1 Histórico

O conceito de neurônio artificial surgiu através do trabalho pioneiro de McCulloch e Pitts, 1943, no qual os pesquisadores empenharam-se em descrever um modelo artificial de neurônio biológico e apresentar suas capacidades computacionais sem entrar no mérito das técnicas de aprendizado. O modelo de neurônio de McCulloch e Pitts, também denominados neurônios MCP em referência aos nomes dos autores, é apresentado na Figura 3.1.




Figura 3.1 - Neurônio de McCulloch e Pitts [adaptado de Guarnieri, 2006].

Neste modelo as entradas ( $x_1, x_2, \dots, x_n$ ), originários dos dados de entrada da rede ou das saídas de outros neurônios, são ajustadas pelos pesos sinápticos ( $w_1, w_2, \dots, w_n$ ) das ligações, destacando a limitação (pesos fixos e não ajustáveis). O neurônio faz o somatório ( $\Sigma$ ) dos produtos  $x_i w_i$ , e decide se o neurônio deve ou não disparar, caso este valor seja igual ou superior a um limiar  $\theta$ , o sinal de saída ( $S$ ) do neurônio será igual a 1, e diz-se que o neurônio tem sua saída ativa ou que está excitado, ou se número for menor que o limiar, a saída ( $S$ ) será zero [Guarnieri, 2006 e Braga, 2007].

Hebb, 1949, descobriu que a plasticidade de aprendizagem em redes neurais é oriunda da alteração das conexões (sinapses) de entradas dos neurônios. O autor descreveu que o aprendizado ocorre se as células pré e pós-sinápticas forem ativadas, ou seja, quando se tem um reforço na conexão neuronal.

Um novo modelo empregando neurônios de McCulloch e Pitts, porém com pesos sinápticos ajustáveis foi proposto por Rosenblatt, 1958, e recebeu o nome de *perceptron*. No modelo, os pesos sinápticos eram calibrados de acordo com a saída desejada através de um algoritmo que treinava a rede para executar certos tipos de funções. Além disso, o modelo também é conhecido como “perceptron de uma



camada”, devido ao fato de apenas na camada de saída possuir pesos ajustáveis. As primeiras RNA's, assim como a de Roseblatt, 1958, eram usadas em sua grande maioria para reconhecer e separar grupos de caracteres [Silva, 2010].

Widrow e Hoff, 1960, propuseram uma nova regra de aprendizado, denominada “regra delta”. Esta regra tem por objetivo minimizar o erro de saída de um neurônio com resposta linear através do método do gradiente descendente [Haykin, 2001]. O modelo no qual continha esta nova regra de aprendizado recebeu o nome de ADALINE (*Adaptive Linear Neuron*) e diferente do perceptron, que tem saídas entre 0 e 1, este modelo possui saídas entre -1 e 1. Outra diferença observada é que neste modelo não existe limiar de ativação, o termo de polarização  $\theta$  é utilizado para calcular a saída (S) [Braga, 2007].

Minsky e Papert, (1969), atraíram a atenção para algumas questões que os atuais modelos não eram capazes de executar, devido ao fato de resolverem somente problemas linearmente separáveis. Além disso, os autores destacaram que os algoritmos de aprendizado em modelos perceptrons com mais de uma camada, não garantiam uma boa convergência comparado com os modelos de apenas uma camada. Estas considerações desestimularam muitos pesquisadores, voltando a ser um assunto de ampla discussão apenas em 1982, através do trabalho de Hopfield, 1982, o qual evidenciava a relação entre redes recorrentes auto associativas e sistemas físicos [Haykin, 2001].

Rumelhart et al., 1986, apresentaram um novo algoritmo de treinamento denominado *backpropagation*, no qual apresentou-se contrariedades as críticas de Minsky e Papert, (1969), demonstrando a viabilidade de solucionar problemas complexos através do treinamento de RNA's de múltiplas camadas.

Braga, 2007, descreve que após o ressurgimento do interesse em RNA's até os dias atuais surgiram inúmeras pesquisas na área propondo a variação do algoritmo *backpropagation* com o intuito de obter uma convergência mais rápida.

### 3.2 Arquitetura de RNA's

A escolha das arquiteturas da RNA baseia-se no tipo de problema a ser abordado. Existem três parâmetros básicos para a definição da arquitetura de uma rede,

sendo eles o nº de camadas da rede, nº de neurônios (nodos) em cada camada e tipo de conexão entre neurônios.

Conforme evidenciado no histórico, em relação ao número de camadas, existem redes de uma única camada, que possuem somente um neurônio entre as camadas de entrada e saída da rede, restritas a resolver problemas linearmente separáveis. Por outro lado, as RNA's de múltiplas camadas possuem mais de um neurônio entre uma entrada e uma saída da rede e são empregadas para solucionar problemas de qualquer função linearmente separável ou não [Cybenko, 1988].

Em relação ao número de neurônios a ser empregado, o qual é de suma importância para o desempenho da rede, não existe na literatura uma regra geral para definir a quantidade dos mesmos em um determinado problema. Segundo Braga, 2007, uma das alternativas é a busca por uma estrutura mínima que atenda aos requisitos de minimização do erro quadrático do conjunto de treinamento. Conforme Boser et. al. 1992, a solução de problemas através desta abordagem empírica pode ser caracterizada como minimização de risco estrutural.

Existem duas conexões básicas de arquitetura nas RNA's: as não-recorrentes (ou *feedforward*) e recorrentes (ou *feedback*). As topologias que não possuem realimentação de suas saídas nas entradas são denominadas não-recorrentes e as recorrentes, por outro lado, possuem realimentação de suas saídas nas entradas [Haykin, 2001]. Neste trabalho será frisado futuramente a RNA do tipo não-recorrente, devido o fato da mesma ter sido empregada.

### 3.3 Redes Perceptron de Múltiplas Camadas

Conforme demonstrado na seção anterior à rede *perceptron* é um modelo de rede composto por uma camada de neurônios de entrada e outra de saída que se limita a resolução de problemas linearmente separáveis. Como solução para este tipo de problema foram adicionadas uma ou mais camadas, comumente chamadas de camadas intermediárias, escondidas ou ocultas. Sendo assim, surgiu a chamada rede perceptron de múltiplas camadas, no inglês denominado *Multilayer Perceptron* (MLP), a qual é composta por um conjunto de entradas, uma ou mais camadas intermediárias e uma camada de saída. A Figura 3.2 ilustra uma RNA do tipo MLP com duas camadas intermediárias.




Figura 3.2 - Representação gráfica de uma RNA do tipo MLP com duas camadas intermediárias, [adaptado de Fiorin et. al., 2011].

Diversos autores desconsideram o termo “camada de entrada”, pois ela apenas recebe e distribui os dados, não realizando nenhuma operação matemática (ponderação, somatório ou comparação com limiares), desta forma assume-se somente o termo “entrada” [Wasserman, 1989].

A diferença entre os neurônios do modelo perceptron de uma camada e de múltiplas é que os neurônios do MLP permitem a saída de um valor qualquer ao contrário do perceptron, que faz somatório ponderado das entradas comparado a um limiar produzindo um sinal de saída 0 ou 1 (binário). Sendo assim, foram criados novos modelos de neurônios artificiais, aplicando nos mesmos funções de ativação nos valores ponderados da entrada. Na Figura 3.3 apresenta-se um neurônio genérico em uma estrutura de rede do tipo MLP.




Figura 3.3 - Modelo de um neurônio de uma rede MLP, [Adaptado de Haykin, 2001].

Na Figura 3.3,  $v_j$  corresponde ao nível de atividade interna do neurônio, o qual é obtido através da combinação do somatório das entradas ponderadas ( $x_i w_{ji}$ ) com outro valor ajustável, denominado bias ( $b_j$ ). Ao aplicar o nível de atividade interna a uma função de ativação ( $\varphi(\cdot)$ ) produz-se a saída ( $y_j$ ). A função de ativação do neurônio age sobre a superfície de mapeamento definido pelos seus pesos, onde seu principal objetivo é introduzir uma não linearidade no modelo. Desta forma, sem a função de ativação, o poder computacional do neurônio, e mesmo de uma rede neural inteira, seria análogo ao de uma transformação linear, conseqüentemente não permitindo a solução de problemas não lineares [Silva et al., 2010]. O bias representa um função semelhante ao limiar  $\theta$  do neurônio de McCulloch e Pitts, 1943, pois o mesmo tem o efeito de diminuir ou aumentar a entrada líquida da função de ativação, dependendo se ele é negativo ou positivo, respectivamente [Haykin, 2004 e Fiorin, 2011]. As Equações (3.1 e 3.2) descrevem todas estas considerações para o neurônio  $j$ .

$$v_j = \sum_{i=1}^m x_i w_{ji} + b_j \quad (3.1)$$

$$y_j = \varphi(v_j) \quad (3.2)$$

A extração das características do problema é realizada na camada intermediária e em geral são empregadas como funções de ativação às funções logarítmicas ou sigmóides [Reidmiller, 1994]. As funções de ativação frequentemente empregadas são a função degrau (empregada por McCulloch e Pitts, 1943), função linear e as funções sigmóides logística e tangente hiperbólica, evidenciadas nas Equações (3.3), (3.4), (3.5) e (3.6) respectivamente [Braga et al., 1998 e Haykin, 2001].

Função Degrau

$$\varphi(v_j) = \begin{cases} +\kappa & \text{se } v_j \geq 0 \\ -\kappa & \text{se } v_j < 0 \end{cases} \quad (3.3)$$

Função Linear

$$\varphi(v_j) = \alpha v_j \quad (3.4)$$

### Função Sigmóide Logística

$$\varphi(v_j) = \frac{1}{1 + \exp(-\alpha v_j)} \quad (3.5)$$

### Função Sigmóide Tangente Hiperbólica

$$\varphi(v_j) = \tanh\left(\frac{v_j}{2}\right) = \frac{1 - \exp(-v_j)}{1 + \exp(-v_j)} \quad (3.6)$$

Conforme Haykin, 2001, as funções de ativação ( $\varphi$ ) são configuradas para uma pequena faixa de valores. A função degrau comumente possui valor  $\kappa = 1$ , podendo ser redefinida para que saídas encontrem-se dentro do intervalo de 0 a 1, proposto por McCulloch e Pitts, 1943, em seu modelo de neurônio. No caso da função linear, a definição de  $\alpha = 1$  permite que a saída do neurônio seja igual ao nível de atividade interna. As funções sigmóides são as mais utilizadas em aplicações de RNA's, por serem estritamente crescentes, diferenciáveis, contínuas e não lineares [Braga et al., 2007]. As funções sigmóides logística e tangente produzem saídas entre 0 e 1, e entre -1 e 1, respectivamente. A Figura 3.4 evidencia os exemplos de funções de ativação.




Figura 3.4 - Exemplos funções de ativação: (a) função degrau; (b) função linear; (c) função logística; (d) função tangente hiperbólica, [adaptado de Haykin, 2001].

## 3.4 Processos de Aprendizagem

Segundo Osório et al., 2000, o aprendizado é a capacidade de se adaptar, modificar e aprimorar as respostas e comportamentos, além de ser um atributo fundamental dos seres chamados de inteligentes, sejam eles humanos ou não. A

habilidade de generalizar diz respeito à aptidão de um sistema de “Aprendizado de Máquina” em aprender através de exemplos e/ou dados apresentados (“adquirir experiência”), e ser capaz de apresentar as saídas corretamente para entradas novas e ainda não vistas por ele [Bishop, 2006].

O processo de aprendizagem ou treinamento baseia-se na apresentação de um conjunto de exemplos a RNA, a qual ajusta os seus pesos sinápticos através de iterações, buscando extrair as características para representar as informações fornecidas a ela [Silva, 2010]. Estes pesos sinápticos são armazenados em uma espécie de memória e utilizados quando novos valores de entrada (novas amostras) são apresentados à rede, gerando resultados.

Os processos de aprendizagem podem ser classificados em supervisionados e não supervisionados. Considera-se um aprendizado não supervisionado, como o próprio nome evidencia, quando não há um “supervisor externo”, ou seja, somente os padrões de entrada estão disponíveis à rede. No treinamento supervisionado, existe um supervisor externo, que fornece a rede tanto os valores de entrada disponíveis quanto os valores de saída esperados. Para cada vez que for apresentada à rede uma entrada, será verificado se a saída obtida após a simulação é igual ou muito próxima à saída almejada para a respectiva entrada [Barreto, 1999]. Caso o valor encontrado seja diferente, a rede deverá ajustar os pesos novamente, até que o erro fique próximo do valor desejado, armazenando o conhecimento obtido. Este método de aprendizagem é um dos mais empregados na literatura, [Braga et al., 2007] e será utilizado nesta dissertação. A Figura 3.5 ilustra um exemplo de aprendizado supervisionado.

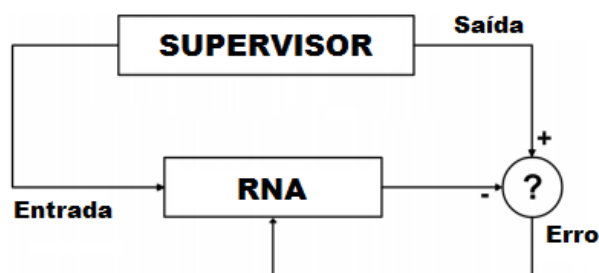


Figura 3.5 – Aprendizado supervisionado, [adaptado de Haykin, 2001].

O aprendizado supervisionado pode ser classificado em treinamento dinâmico e treinamento estático. No caso do treinamento dinâmico acontecem mudanças na

estrutura de rede, tais como, redução ou acréscimo do n° de camadas, n° de nodos em cada camada e n° de conexões [Barreto, 1999]. Ainda segundo o autor, no treinamento estático a única alteração que ocorre são nos pesos sinápticos, e a arquitetura da rede permanece inalterada, sendo este tipo de treinamento empregado neste trabalho. Em suma, considerando um neurônio de saída  $j$ , a cada iteração  $t$  é gerado um sinal de erro  $e_j(t)$ , calculado através da diferença entre o valor de saída do neurônio  $y_j(t)$  e a saída desejada,  $d_j(t)$  (ou valor alvo), conforme demonstra a Equação (3.7).

$$e_j(t) = d_j(t) - y_j(t) \quad (3.7)$$

Desta forma, em cada iteração são realizadas pequenas modificações nos pesos sinápticos, gerando uma minimização incremental do erro, objetivando a convergência ao valor esperado e um erro menor na próxima iteração  $(t+1)$ :

$$w_{ji}(t + 1) = w_{ji}(t) + \Delta w_{ji}(t) \quad (3.8)$$

onde,  $w_{ji}(t)$  é o peso sináptico da conexão do neurônio  $j$  com o neurônio  $i$  da camada anterior e o ajuste aplicado ao peso é  $\Delta w_{ji}(t)$ , fazendo com que na próxima iteração o peso assuma um novo valor  $w_{ji}(t + 1)$ .

Conforme Braga, 2007, a diferença entre os algoritmos de aprendizagem baseia-se basicamente na fórmula com que  $\Delta w_{ji}(t)$  é calculado. Porém uma forma genérica de atualização dos pesos por correção de erros é apresentada na Equação (3.9):

$$w_{ji}(t + 1) = w_{ji}(t) + \eta e_j(t) x_i(t) \quad (3.9)$$

onde,  $x_i(t)$  é a entrada para o neurônio  $i$  no tempo  $t$  e  $\eta$  é a taxa de aprendizado, que define a velocidade com que os pesos serão ajustados buscando o menor erro  $e_j(t)$ . A obtenção da equação de ajuste dos pesos em diferentes modelos de RNA's utiliza a soma dos erros quadráticos de todas as saídas como parâmetro de desempenho da rede e também como função de custo (Equação (3.10)), que tem por objetivo ser minimizada pelo algoritmo de treinamento:

$$E(t) = \frac{1}{2} \sum_j (d_j(t) - y_j(t))^2 = \frac{1}{2} \sum_j e_j^2(t) \quad (3.10)$$

Na fase de aprendizado a função custo representa uma medida de desempenho do sistema, dependente dos pesos e bias. Desta forma, pode-se representar a função de custo na forma de uma superfície de erro, empregando os pesos e bias como coordenadas [Haykin, 2001]. Conforme Braga, 1998, no caso da utilização de funções de ativação lineares a superfície de erro pode apresentar um único ponto de mínimo e no caso de funções não lineares pode apresentar vários mínimos locais além do mínimo global. Na Figura 3.6 ilustra-se, para uma melhor compreensão, uma superfície de erro para dois pesos, apresentando o mínimo local e mínimo global.




Figura 3.6 – Superfície de erro para dois pesos e exemplos de mínimo global e local, [adaptado de Raizer et al., 2009].

No decorrer do aprendizado as combinações dos pesos e bias, conjunto este também denominado de parâmetros livres, tendem em direção a um ponto de mínimo na superfície de erro e esta direção é definida através do *gradiente* da superfície em cada ponto [Haykin, 2001]. Desta forma, a minimização da função de custo (Equação (3.10))



que conduz a regra delta é denominada de *método o gradiente para minimização do erro*, em que sempre no sentido inverso do gradiente os pesos são ajustados:

$$\Delta \vec{w} = -\eta \cdot \nabla E(\vec{w}) \quad (3.11)$$

onde, conforme Haykin, 2001,  $\vec{w}$  é um vetor que possui todos os pesos e o bias do neurônio,  $\nabla E(\vec{w})$  corresponde ao gradiente da função de custo (Equação (3.10)) do vetor  $\vec{w}$  (com a mesma dimensão do vetor  $\vec{w}$ ), e onde cada componente é a derivada parcial de  $E(\vec{w})$  com relação a cada peso em  $\vec{w}$ .

Durante a etapa de aprendizado ou treinamento existem dois principais critérios de parada: o erro de saída da rede (método mais utilizado) ou o número de épocas (apresentação de todos os padrões de treinamento disponível corresponde a uma época). Segundo Haykin, 2001, um valor alto de  $\eta$  pode aumentar a velocidade do treinamento, porém também pode fazer com que um mínimo global não seja alcançado. Por outro lado, um valor baixo de  $\eta$  diminui a velocidade de treinamento, porém aumenta a probabilidade do mesmo em convergir para um mínimo global. Ainda conforme o autor, para determinar o momento de parada e avaliar o desempenho da rede são definidos três grupos com funções objetivos distintos sobre os dados empregados, denominados de conjunto de treinamento, validação e teste. Na sequência serão explicados os três grupos através das considerações do autor.

O conjunto de treinamento refere-se à parcela de dados que será utilizado para o aprendizado da RNA, no qual a partir deles o modelo fará o ajuste dos pesos. O recomendado é que este conjunto contenha a maior parecia de dados comparado aos outros dois grupos, pois definirá o funcionamento da MLP e desta forma o modelo reconhecerá a maior quantidade de padrões existente entre os dados.

O conjunto de validação é usado para avaliar o treinamento e determinar a parada do mesmo, porém não é empregado na aprendizagem e utiliza-se dados fora da amostra de treinamento. Este conjunto tem o objetivo de evitar problemas de *Overfitting* (excesso de ajuste, neste caso a rede não extrai padrões e somente memoriza os dados).

O conjunto de Teste é muito semelhante ao grupo de validação, entretanto ele somente é empregado após toda etapa de treinamento ter sido finalizada. O conjunto tem como objetivo avaliar a performance, através da medida de erro escolhido, do sistema já concluído.

Outro problema que pode ocorrer durante o aprendizado, além do *Overfitting*, é o *Underfitting*, definido pela incapacidade do modelo de aprendizado em generalizar o problema que lhe foi exposto [Braga et al., 1998]. Resumidamente, o modelo de aprendizado não consegue encontrar a relação (padrões) entre os valores de entradas e as saídas desejadas (valor alvo) durante o tempo de treinamento. A Figura 3.7 apresenta um exemplo para a determinação de parada de treinamento de uma RNA do tipo MLP usando os erros do conjunto de treinamento e validação [Andrade Filho, 2016].

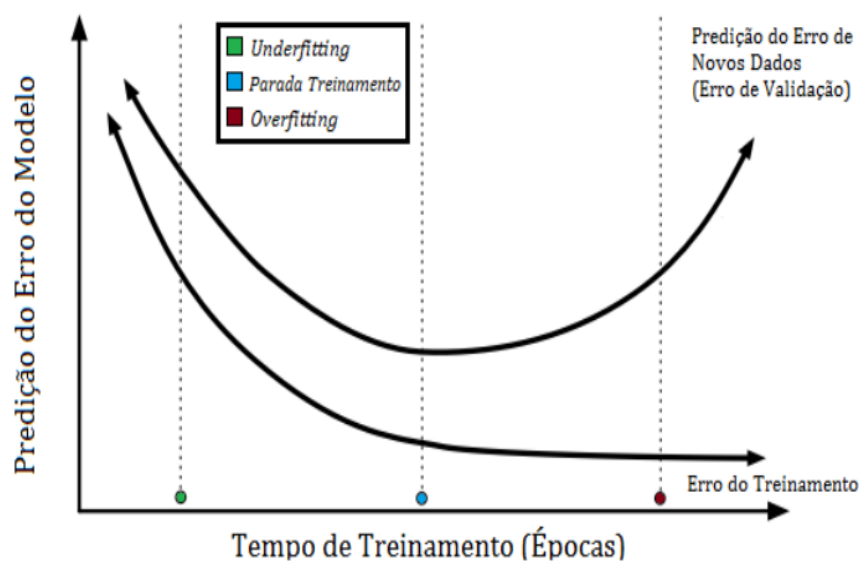


Figura 3.7 – Exemplos de erros em treinamento de uma rede do tipo MLP [Andrade Filho, 2016].

Conforme demonstrado na Figura 3.7 e destacado pelo autor, o ponto de cor verde indica a situação de *Underfitting*, onde ambos os erros (treinamento e validação) estão altos e ainda decaindo. O ponto em vermelho representa a situação de *Overfitting*, na qual o erro para o conjunto de treinamento é baixo, porém o erro do conjunto de validação é alto, tendo este crescido depois de determinado ponto. O ponto indicado na cor azul representa a localização na qual o treinamento deve ser finalizado, pois a partir deste ponto o erro de validação começa a aumentar, demonstrando que o modelo está perdendo capacidade de generalização do problema.

Haykin, 2001, destaca sobre a importância da divisão dos dados (treinamento, teste e validação) e o problema envolvido, pois cada amostra pode conter representatividades diferentes o que influenciará diretamente no erro.

Para definir a capacidade de generalização de uma MLP um fator muito importante é método pelo qual é realizado o ajuste ou calibração dos pesos [Reidmiller, 1994]. Para esta tarefa será considerado nesta dissertação o método *backpropagation* (retropropagação), sendo este um algoritmo de treinamento supervisionado para redes do tipo MLP, que segundo diversos autores [Barreto, 1999; Haykin, 2001; Braga et al., 2007; Silva et al., 2010], é um dos mais empregados e difundidos na literatura.

### 3.4.1 O Algoritmo Backpropagation (Retropropagação)

O algoritmo *backpropagation* (BP) foi descrito de uma forma clara por Rumelhart et al., 1986 para ser utilizado no treinamento supervisionado de redes *feedforward* com múltiplas camadas [Wasserman, 1989]. Este algoritmo dividi-se em duas fases, na primeira fase, denominada *forward*, uma entrada é aplicada à rede neural e seu sinal funcional é propagado pela rede, camada a camada até a saída, mantendo seus pesos fixos. Na segunda fase, denominada *backward*, a saída é comparada com o alvo gerando um sinal de erro e por sua vez este sinal é propagado da saída para a entrada, ajustando os pesos com o objetivo de minimizar o erro [Rumelhart et al., 1986; Haykin, 2001; Braga 2007]. O algoritmo *backpropagation* é baseado na regra delta [Widrow e Hoff, 1960], porém ele não ajusta somente os pesos da camada de saída e sim de todas as camadas da rede.

Conforme descrito por Braga et al., 2007, a diferença entre os algoritmos de aprendizado encontra-se no modo pelo qual é calculado o ajuste dos pesos ( $\Delta w_{ji}(t)$ ). Apresentar-se-á nesta dissertação as principais equações do algoritmo *backpropagation*, pois a dedução completa do modelo foge do objetivo deste trabalho, sendo possível verificar a dedução completa em Rumelhart et al., 1986, Haykin, 2001 ou Braga et al., 2007.

Neste algoritmo o ajuste dos pesos baseia-se no método do gradiente para minimização de erro (Equação (3.11)), isto é, a correção aplicada a cada peso sináptico do neurônio  $j$  de saída se dá através da derivada parcial da função de custo  $E(t)$ , (Equação (3.10)), em relação ao peso analisado, conforme demonstrado nas Equações (3.12) e (3.13):

$$\frac{\partial E(t)}{\partial w_{ji}} = -e_j(t) \cdot \varphi'_j(v_j(t)) \cdot x_i(t) \quad (3.12)$$

$$\Delta w_{ji}(t) = -\eta \frac{\partial E(t)}{\partial w_{ji}} = \eta \cdot e_j(t) \cdot \varphi'_j(v_j(t)) \cdot x_i(t) \quad (3.13)$$

onde,  $\varphi'_j(v_j(t))$  é a derivada da função de ativação aplicada ao nível de atividade interna do neurônio. Agrupando os termos de sinal erro,  $e_j(t)$ , correspondente para aquele neurônio e a derivada da função de ativação associada,  $\varphi'_j(v_j(t))$ , obtêm-se o chamado gradiente local,  $\delta_j$ , que aponta para as modificações necessárias nos pesos sinápticos [Haykin, 2001]:

$$\delta_j = e_j(t) \cdot \varphi'_j(v_j(t)) \quad (3.14)$$

Desta forma, reescrevendo a Equação (3.13), obtêm-se o ajuste dos pesos de um neurônio  $j$  qualquer da camada de saída:

$$\Delta w_{ji}(t) = -\eta \frac{\partial E(t)}{\partial w_{ji}} = \eta \cdot \delta_j \cdot x_i(t) \quad (3.15)$$

Após o cálculo do erro propagado até a saída (fase *forward*) os neurônios da camada intermediária tem sua parcela de responsabilidade sobre o ocorrido, desta forma dá-se início a fase *backward*, para que os mesmos sejam calibrados e minimizados através da retropropagação [Braga et al., 1998]. Considerando agora que neurônio intermediário corresponde ao neurônio  $j$ , conectado a neurônios  $k$  da camada de saída, o gradiente local é calculado através da Equação (3.16):

$$\delta_j(t) = \varphi'_j(v_j(t)) \cdot \sum_k \delta_k(t) w_{kj}(t) \quad (3.16)$$

onde,  $\sum_k \delta_k(t)$  é somatório dos gradientes locais de cada neurônio  $k$  da camada seguinte,  $w_{kj}(t)$  é a ponderação das conexões sinápticas que ligam cada neurônio  $k$  ao neurônio  $j$  e  $\varphi'_j(v_j(t))$  é a derivada da função de ativação aplicada ao nível de atividade interna do neurônio. Desta forma, o ajuste dos pesos da camada oculta é realizado através da substituição da Equação (3.16) na Equação (3.15):

$$\Delta w_{ji}(t) = \eta \cdot \varphi'_j(v_j(t)) \cdot \sum_k \delta_k(t) w_{kj}(t) \cdot x_i(t) \quad (3.17)$$

Com o objetivo de aumentar a velocidade de aprendizagem sem tornar a rede instável e sem aumentar a taxa de aprendizagem,  $\eta$ , emprega-se um método que modifica a Equação (3.11) através da adição de um termo de *momentum* ( $\beta$ ), proposto por (Rumelhart et al., 1986) em seu modelo:

$$\Delta w_{ji}(t) = -\eta \frac{\partial E(t)}{\partial w_{ji}} + \beta \Delta w_{ji}(t-1) \quad (3.18)$$

onde, o termo momentum relaciona as alterações dos pesos na iteração  $t$  com as mesmas realizadas na iteração anterior ( $t-1$ ). Segundo o autor, a adição deste termo dificulta a mudança de tendência na atualização dos pesos, além de ser empregada para minimizar a probabilidade da ocorrência de mínimos locais.

### 3.5 RNA's Aplicadas para Previsão de Demanda e Geração de Energia Elétrica

Nesta seção, serão evidenciados alguns trabalhos que empregam a técnica das RNA's no contexto da previsão energética, restringindo-se apenas a previsão de demanda e geração de energia elétrica em diferentes horizontes. Associado a este tema, tais horizontes de previsão podem ser classificados em curtíssimo, curto, médio e longo prazo. Além disso, abordar-se-á as variáveis empregadas nos modelos e algumas técnicas, as quais servirão de justificativas para as escolhas feitas na metodologia desta dissertação.

Inicialmente devem ser descritas as diferenças entre estes horizontes, sendo estes classificados através da escala de tempo. Na previsão de curtíssimo prazo, o horizonte projetado é de alguns minutos até uma hora à frente e na de curto prazo, de horas até uma semana à frente. Na previsão em um horizonte de médio prazo, a faixa se estende de períodos superiores a uma semana, a alguns meses (máximo um ano). Por fim, segundo Morettin e Toloi, 2006, a previsão em um horizonte de longo prazo refere-se a períodos superiores a um ano.

Segundo Serrão, 2003, e Rodrigues, 2002, no contexto energético, as previsões de médio e curto prazo geralmente levam em consideração a carga histórica, dados

climáticos, o número de consumidores, a economia, dentre outros. Bashir e Hawary, 2009, descreve que a previsão no curto prazo é muito importante para as concessionárias de energia, pois a partir dela decisões como agendamento de geração, manutenção de carga e avaliação da segurança do sistema são tomadas. Nos sistemas elétricos de potência a previsão de curto e médio prazo garante uma operação mais segura e econômica [Tripathi et al., 2008].

Carmona, 2002, cita que nas previsões no longo prazo são geralmente, empregadas informações de carga e socioeconômicas. Além disso, projeções deste tipo permitem que estratégias sejam definidas para suprir a demanda, através da construção de novas usinas (geração) e expansão do sistema (transmissão e distribuição).

Com base nas informações descritas até o momento pode-se observar que os horizontes de previsão têm relação direta com consumo, demanda, tempo, condições meteorológico-climáticas, informações socioeconômicas, entre outros. Na sequência serão apresentados alguns trabalhos que utilizam RNA's em diferentes horizontes de previsão.

Charytoniuk e Chen, 2000, empregaram RNA's para prever, em um horizonte de curtíssimo (previsão de até uma hora em intervalo de minutos), a demanda de energia elétrica de uma empresa americana. Eles fizeram uso de informações referentes à carga, tempo e dados meteorológicos na matriz de entrada da rede. Os autores obtiveram um Erro Percentual Absoluto Médio (MAPE – Mean Absolut Percentage Error), entre 0,66% e 1,25% em seu modelo de previsão. Além disso, analisando os resultados eles concluíram que para esta situação específica de curtíssimo prazo, o foco não deve ser voltado não para a relação da demanda com fatores que a influenciariam como condições meteorológicas e sim com o padrão apresentado pelas últimas leituras registradas.

Becalli et al., 2004, fizeram uso das redes neurais para previsão de demanda de energia elétrica no curto prazo, combinando a abordagem supervisionada e não supervisionada. Os autores classificaram previamente os dados históricos de demanda durante a etapa não supervisionada, e durante a etapa supervisionada realizaram o treinamento de uma RNA do tipo MLP para concluir o processo de previsão. Além disso, empregaram como entradas em seu modelo informações meteorológicas, como temperatura, umidade relativa do ar e radiação solar. Para a respectiva abordagem, os autores obtiveram um erro médio de 1,97%, erro máximo de 3,81% e erro mínimo de

0,09%. Com base nisso, os mesmos classificaram as RNA's como uma ferramenta útil para previsão de demanda de energia elétrica no curto prazo.

Khoa et al. (2004), avaliaram em seu estudo três modelos de redes neurais, sendo eles o *Functional Link Networks*, *Multi-Layer Perceptron* e o *Wavelet Networks*. O trabalho tinha por objetivo realizar a previsão de carga (demanda) em um horizonte de longo prazo aplicando na matriz de entrada das RNA's dados econômicos, tais como PIB, Índice Nacional de Preços ao Consumidor Amplo (IPCA) e tarifa de energia elétrica. Os autores empregaram o algoritmo *backpropagation* no aprendizado supervisionado da rede e como resultados obtiveram um MAPE de 3%, considerando o mesmo satisfatório, bem como a aplicação das RNA's em modelos de previsão.

Methaprayoon et al., 2007, empregou redes neurais para prever a geração de energia eólica em um horizonte de médio prazo (mês) utilizando dados de um parque eólico localizado em *Lawton City*. Os autores selecionaram como entradas a medição da velocidade do vento e o último valor registrado de geração de energia eólica (valor registrado uma hora antes). Os dados disponíveis foram divididos em dois conjuntos: treinamento (dados de maio de 2002 a julho de 2002 em intervalos horários) e teste (agosto e novembro de 2002 e janeiro de 2003). Os resultados das previsões empregando os dados de teste da rede apresentaram erros percentuais de 3,6502% para agosto, 3,0706% para novembro e 5,7557% para janeiro respectivamente. Outro resultado apresentado pelos mesmos refere-se ao nível de confiança entre a previsão e o dado observado, demonstrado que o emprego do método das RNA's obteve resultados satisfatórios.

Yona et al., 2007, em seu artigo levaram em consideração a insolação de cada mês (médio prazo) e confirmaram a validade do uso de redes neurais para prever insolação 24 horas a frente (curto prazo) e potência gerada por um painel fotovoltaico. Os autores empregaram em seu modelo dados meteorológicos como entradas da RNA (insolação, temperatura, umidade relativa do ar, quantidade de nuvens, pressão atmosférica, velocidade do vento e precipitação), nos quais foram separados em seis grupos, contendo quantidades diferentes de dados em cada um deles. Os resultados do MAPE para potência de saída do painel fotovoltaico no período de janeiro a dezembro de 2003, em intervalos mensais, apresentou um valor mínimo de em torno de 12%, além disso, os autores destacam que, de fato é possível realizar previsões usando apenas dados meteorológicos em curto espaço de tempo.

Abdel-Aal, 2008, comparou dois métodos distintos (*abductive networks* e RNA's) para prever a demanda de energia elétrica no médio prazo na Arábia Saudita. O autor descreve que informações referentes ao clima, socioeconômicas, demográficas e tempo exercem influencia sobre a demanda de energia elétrica. O estudo utiliza a modelagem univariada da série de tempo de demanda mensal baseada apenas em dados de 6 anos para prever a demanda para o sétimo ano. Os dois métodos empregados foram comparados entre si, porém com duas abordagens diferentes: na primeira abordagem o autor fez o uso de um único modelo iterativo para previsão de demanda um mês à frente por doze vezes e, na segunda abordagem, foram criados doze modelos, cada um para prever a de demanda de um determinado mês ao longo do período de um ano. A primeira abordagem obteve um resultado mais eficiente para os dois modelos, cujos MAPE foram de 3,2% para o método *abductive networks* e 3,8% para as RNA's.

Mais recentemente, Uzlu et al., 2014, utilizaram RNA's em parceria com o algoritmo Colônia de Abelhas Artificiais (ABC – do inglês *Artificial Bee Colony*) para estimar a energia hidrelétrica anual da Turquia (longo prazo). A demanda bruta de energia elétrica, população, temperatura média anual e consumo de energia elétrica foram selecionados como variáveis de entrada no modelo. Os autores realizaram simulações comparando os modelos *backpropagation* e ABC, os quais demonstraram que o método ABC previu geração hidrelétrica melhor do que o algoritmo BP, registrando um erro relativo médio de 4,5599% para o ABC e de 5,202% para o algoritmo BP. Além disso, os resultados estimam que a futura geração hidrelétrica na Turquia vá variar de 69,1 para 76,5 TWh em 2021, e a demanda anual total de eletricidade representada pelas taxas de fornecimento de energia hidrelétrica de 14,8% para 18,0%.



## 4 METODOLOGIA

### 4.1 Introdução

No presente trabalho fez-se o uso de RNA's para prever a geração de energia elétrica no estado do RS em um horizonte de médio prazo (um ano). Inicialmente foram selecionados e agrupados dados que exerçam influência sobre o resultado esperado, com o objetivo de que padrões de reconhecimento entre os mesmos sejam criados para prever comportamentos futuros. Conforme evidenciado na maioria dos trabalhos apresentados na seção 3.5, informações referentes à energia elétrica (dados passados de geração, consumo, demanda, entre outros), economia e meteorologia possuem relação direta sobre as previsões realizadas e nesta dissertação dados deste tipo serão utilizados. Informações deste gênero podem ser empregadas para criar um conjunto de dados, denominada no contexto da RNA's como matriz de entrada ou simplesmente entrada. Respectivamente, para cada conjunto de dados da matriz de entrada existe um dado alvo, sendo este denominado de matriz alvo, contendo o dado real (observado), no caso deste trabalho a geração de energia elétrica do RS.

Dentro do contexto das RNA's existem inúmeros modelos e configurações para criação das mesmas, porém cada uma possui sua peculiaridade e meio de aplicação mais adequado, [Haykin, 2001 e Braga et al., 2007]. A criação e configuração de uma rede baseiam-se principalmente na escolha do seu tipo, número de camadas escondidas e de neurônios, função de treinamento, adaptação da função de aprendizagem, desempenho da função, função de transferência, quantidade de elementos para treinamento, validação e teste. Deve-se enfatizar que qualquer mudança na configuração de uma rede pode ocasionar resultados extremamente diferentes e um domínio sobre a técnica e a literatura torna-se essencial para tentar analisar possíveis erros ou resultados não esperados.

Na sequência, depois de realizada a configuração anunciada anteriormente, conclui-se a criação da RNA e dá-se início ao seu treinamento, teste e validação, que tem por objetivo certificar e evidenciar ao usuário que as escolhas feitas pelo mesmo estão corretas ou dentro dos intervalos desejados. Caso os resultados não apresentem valores dentro do intervalo esperado à rede pode ser reconfigurada e simulada novamente, porém, caso o erro persista, a metodologia empregada, neste caso redes

neurais, pode estar não encontrando padrões de reconhecimento e poderá ser substituída por outra mais adequada.

Por fim, considerando que o treinamento, teste e validação da RNA ocorreram de forma satisfatória, pode-se empregá-la para prever os dados desejados (geração de energia elétrica no RS). Sendo assim, adiciona-se uma matriz de previsão com as mesmas variáveis da matriz de entrada, porém com amostras distintas, as quais serão empregadas para realizar a predição almejada.

Uma maneira clara de analisar os resultados de treinamento e previsão da RNA é compará-los graficamente com os valores reais e também através dos cálculos do erro (absoluto, médio, MAPE), por exemplo.

Até o presente momento realizou-se uma breve descrição sobre os principais tópicos da metodologia deste trabalho, no entanto, devido à quantidade de etapas e especificações necessárias a serem implementadas, dividiu-se a mesma em três módulos, apresentados a seguir:

- Módulo I: Aquisição e classificação dos dados para as entradas da RNA.
- Módulo II: Criação, configuração, treinamento, teste e validação da RNA.
- Módulo III: Previsão da geração de energia elétrica e processamento dos resultados da previsão.

#### **4.2 Módulo I: Aquisição e classificação dos dados para as entradas da RNA**

Neste módulo fez-se a aquisição dos dados para elaboração da matriz de entrada da RNA, bem como sua classificação por temática, totalizando três áreas: dados do balanço de energia elétrica, dados econômicos e dados meteorológicos.

- Dados referentes ao balanço de energia elétrica:

Os dados referentes ao balanço de energia elétrica do estado do Rio Grande do Sul foram disponibilizados pela Diretoria de Planejamento e Projetos Especiais do Grupo CEEE. É importante salientar novamente que o grupo CEEE é responsável pela elaboração do relatório do Balanço Energético do Rio Grande do Sul (BERS), o qual apresenta a contabilização da oferta e consumo de energia no estado, além de panoramas e tendências mundiais e nacionais.

As informações técnicas são referentes à importação e exportação de energia elétrica do SIN e internacional, carga própria de energia (energia elétrica que o estado consome menos a exportação do SIN e internacional) e geração de energia elétrica derivada de três fontes (hídrica, térmica e eólica), possuindo uma periodicidade mensal, entre janeiro de 2009 a março de 2016. A composição destas informações descreve o balanço de energia elétrica no estado durante o período descrito. A Tabela 4.1 demonstra as variáveis empregadas neste estudo, com suas respectivas unidades de medida.

Tabela 4.1 - Variáveis referentes ao balanço de energia elétrica do RS

| <b>Variáveis Energéticas</b>        | <b>Unidade de Medida</b> |
|-------------------------------------|--------------------------|
| Geração Hidráulica                  | %                        |
| Geração Térmica                     |                          |
| Geração Eólica                      |                          |
| Importação de Energia no SIN        | MW médio                 |
| Exportação de Energia no SIN        |                          |
| Importação Internacional de Energia |                          |
| Exportação Internacional de Energia |                          |
| Carga Própria de Energia do RS      |                          |

Os respectivos dados não são apresentados de forma individual e em intervalos mensais no relatório do BERS, evidenciando assim uma aplicação inédita do conjunto de informações dentro do contexto das redes neurais artificiais. Salienta-se que, dados deste gênero e nestas condições de detalhamento são muito difíceis de serem encontrados na literatura e em buscas via meio eletrônico, o que em muitas vezes inviabiliza determinadas pesquisas e estudos. Os principais dados referentes ao balanço de energia elétrica foram apresentados no capítulo 2, sendo eles a geração de energia elétrica para as três fontes (Figura 2.7), importação de energia elétrica do SIN (Figura 2.10), exportação de energia elétrica para o SIN (Figura 2.11) e exportação internacional de energia elétrica (Figura 2.12). Destacou-se ainda naquele capítulo que durante o período de janeiro de 2009 a março de 2016 (87 meses), a importação internacional de energia, feita através do RS, ocorreu somente em três meses, sendo

eles, outubro, novembro e dezembro de 2009, importando 9,21, 1,82 e 1,72 MW médio, respectivamente. O comportamento da carga própria de energia elétrica no estado é demonstrado na Figura 4.1, desta forma serão apresentados todos os dados referentes ao balanço de energia elétrica do RS no período entre janeiro de 2009 e março de 2016.




Figura 4.1 - Carga própria de energia elétrica do estado.

- Dados Econômicos (Estadual e Nacional)

Nesta dissertação, limitou-se a empregar apenas dados com periodicidade mensal, porém muitos dados econômicos encontravam-se com periodicidade trimestral, semestral ou anual, como por exemplo, PIB, importações e exportações. Desta forma os mesmos não foram utilizados, pois o comportamento deles em intervalos mensais é influenciado por inúmeros fatores antrópicos e/ou naturais.

As informações referentes ao setor econômico do estado e do país que possuem periodicidade mensal, tais como o Imposto sobre Circulação de Mercadorias e Serviços (ICMS), o Índice Nacional de Preços ao Consumidor Amplo (INPC), também conhecido como IPCA e o Índice Geral de Preços – Mercado (IGP-M) foram empregadas neste trabalho e retiradas do *site* do Instituto de Pesquisa Econômica Aplicada (IPEA), [IPEADATA, 2016]. Deve-se enfatizar que, o ICMS é um dado estadual e o IPCA e IGP-M são dados a nível nacional.

O ICMS, definido como o tributo que incide sobre a movimentação de produtos no mercado interno e sobre serviços de transporte (interestadual e intermunicipal), comunicação e bens importados em geral, a fim de promover um tratamento tributário igualitário para os produtos importados e os nacionais é um principais indicadores econômicos do estado [Atlas Socioeconomico do RS, 2016]. Marques Junior e Oliveira 2014, descrevem que o ICMS, cuja base de tributação é o consumo, é a principal fonte de receita, representando cerca de 90% da receita tributária estadual.

O IPCA, um dos principais indicadores econômicos do país, tem a finalidade de medir variações do nível de preços de um conjunto de bens e serviços ao longo do tempo [IPEADATA, 2016]. Trata-se de um indicador da inflação do consumo pessoal e abrange famílias com renda de 1 a 40 salários mínimos, o que responde por aproximadamente 90% dos residentes nas áreas de cobertura (regiões metropolitanas de Belém, Belo Horizonte, Curitiba, Fortaleza, Porto Alegre, Salvador, São Paulo, Recife, Rio de Janeiro e Vitória, além do Distrito Federal e dos municípios de Goiânia e Campo Grande), [IBGE, 2014].

O IGP-M registra o ritmo evolutivo de preços como medida síntese da inflação nacional. É composto pela média ponderada do Índice de Preços por Atacado (IPA) (60%), Índice de Preços ao Consumidor (IPC-FGV) (30%) e Índice Nacional de Preços da Construção Civil (INCC) (10%), [IPEADATA, 2016].

Padrões e correlações existentes entre energia elétrica e economia são descritos em trabalhos de diversos autores [Carmona, 2002; Serrão, 2003; Rodrigues, 2002; Thoma, 2004; Wolde-Rufael, 2006; Soytaş e Sari, 2009; Ocal e Aslan, 2013 e Bhattacharya et al., 2016], justificando assim a inserção destes elementos a matriz de entrada. A Tabela 4.2 demonstra as variáveis referentes aos dados econômicos, com suas respectivas unidades de medida.

Tabela 4.2 - Variáveis econômicas

| <b>Variáveis Econômicas</b> | <b>Unidade de medida</b> |
|-----------------------------|--------------------------|
| ICMS                        | R\$ mil                  |
| Inflação – IPCA             | % a.m.                   |
| Inflação - IGP-M            |                          |

Na Figura 4.2, 4.3 e 4.4 são apresentados os dados referentes ao ICMS, Inflação - IPCA e Inflação IGP-M, respectivamente.




Figura 4.2 – ICMS do RS, [adaptado de IPEADATA, 2016].




Figura 4.3 – Inflação IPCA do Brasil, [adaptado de IPEADATA, 2016].




Figura 4.4 – Inflação IGP-M do Brasil, [adaptado de IPEADATA, 2016].

- Dados Meteorológicos do Estado

As variáveis meteorológicas possuem correlações e padrões evidentes quando comparadas com dados relativos à geração e consumo de energia elétrica, conforme demonstrados na literatura apresentada da seção 3.5 [Charytoniuk e Chen, 2000, Becalli et al., 2004 Yona et al., 2007, Uzlu et al., 2014]. No setor econômico, sabe-se que a meteorologia também possui interferência direta nas atividades relacionadas ao setor primário, secundário e terciário, como por exemplo, a agricultura, pecuária, indústria, comércio e serviços.

Os dados meteorológicos selecionados foram retirados do *site* do Instituto Nacional de Meteorologia (INMET), através do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP), no qual se encontram cadastradas inúmeras estações meteorológicas convencionais realizando medições a 10m (metros) de altura em relação ao nível do solo [BDMEP, 2016]. Essas estações fornecem informações, referentes às medições diárias, de acordo com as normas técnicas internacionais da Organização Meteorológica Mundial (OMM), (INMET, 2016). As variáveis adquiridas e utilizadas nesta dissertação encontram-se na Tabela 4.3 e compreendem o período de janeiro de 2009 a março de 2016, com frequência mensal, para as estações cadastradas no BDMEP

para o estado do RS. Na Tabela 4.4 apresenta-se o código para a variável direção do vento predominante.

Tabela 4.3 - Variáveis meteorológicas

| <b>Variáveis Meteorológicas</b> | <b>Unidade de medida</b>                |
|---------------------------------|---|
| Velocidade do vento média       | m/s                                     |
| Direção do vento predominante   | Código de direção do vento (Tabela 4.4) |
| Precipitação Total              | mm                                      |
| Pressão Atmosférica Média       | mbar                                    |
| Temperatura Máxima Média        | °C                                      |
| Temperatura Mínima Média        |   |
| Umidade Relativa                | %                                       |

Tabela 4.4 – Código de direção do vento

| <b>Código</b> | <b>Descrição</b> | <b>Abreviação</b> |
|---------------|------------------|-------------------|
| 0             | Calma            | C                 |
| 1, 2, 3 e 4   | Norte - Nordeste | NNE               |
| 5 e 6         | Nordeste         | NE                |
| 7 e 8         | Leste - Nordeste | ENE               |
| 9 e 10        | Leste            | E                 |
| 11, 12 e 13   | Leste - Sudeste  | ESE               |
| 14 e 15       | Sudeste          | SE                |
| 16 e 17       | Sul - Sudeste    | SSE               |
| 18 e 19       | Sul              | S                 |
| 20, 21 e 22   | Sul - Sudoeste   | SSW               |
| 23 e 24       | Sudoeste         | SW                |
| 25 e 26       | Oeste - Sudoeste | WSW               |
| 27 e 28       | Oeste            | W                 |
| 29, 30 e 31   | Oeste - Noroeste | WNW               |
| 32 e 33       | Noroeste         | NW                |
| 34 e 35       | Norte - Noroeste | NNW               |
| 36            | Norte            | N                 |
| <b>99</b>     | Variável         | Variável          |

Fonte: adaptada de BDMEP, 2016.



A Tabela 4.5 demonstra o número da estação cadastrada, o município do RS onde localiza-se a mesma e seu respectivo código .

Tabela 4.5 - Cadastro das estações meteorológicas e sua respectiva localização

| <b>Nº da estação cadastrada</b> | <b>Município</b>        | <b>Código</b> |
|---------------------------------|-------------------------|---------------|
| 83980                           | Bagé                    | BA            |
| 83941                           | Bento Gonçalves         | BG            |
| 83919                           | Bom Jesus               | BJ            |
| 83942                           | Caxias                  | CX            |
| 83912                           | Cruz Alta               | CA            |
| 83964                           | Encruzilhada do Sul     | ES            |
| 83881                           | Iraí                    | IR            |
| 83916                           | Lagoa Vermelha          | LV            |
| 83914                           | Passo Fundo             | PF            |
| 83985                           | Pelotas                 | PE            |
| 83967                           | Porto Alegre            | POA           |
| 83995                           | Rio Grande              | RG            |
| 83936                           | Santa Maria             | SM            |
| 83997                           | Santa Vitória do Palmar | SVP           |
| 83953                           | Sant’Ana do Livramento  | SL            |
| 83907                           | São Luiz Gonzaga        | SLG           |
| 83948                           | Torres                  | TO            |
| 83927                           | Uruguaiana              | UR            |

Fonte: adaptada de BDMEP, 2016.

A Figura 4.5 ilustra a localização das estações meteorológicas no estado, citadas na Tabela 4.5.

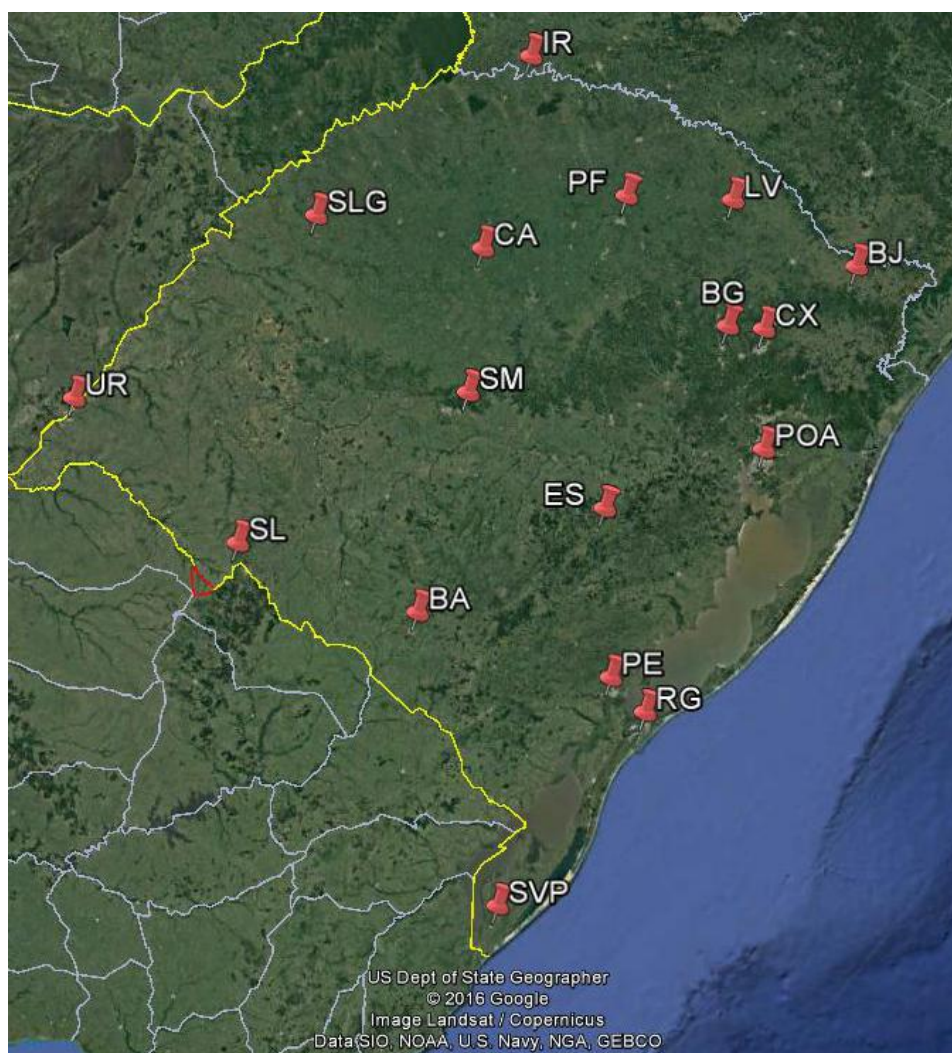


Figura 4.5 – Localização das estações cadastradas pelo INMET, [adaptado de BDMEP, 2016].

Os dados meteorológicos adquiridos foram dispostos em tabelas através do programa Excel® e verificados se continham todas as informações selecionadas, pois algumas vezes os mesmos apresentam falta de informações ou até mesmo valores inconsistentes com a realidade. As estações de Cruz Alta, Encruzilhada do Sul, Iraí, Lagoa Vermelha, Pelotas e Santa Vitória do Palmar apresentaram uma grande falta de informações e neste caso foram descartadas, as demais apresentaram todas as informações corretamente e foram selecionadas.

Devido à ausência de um valor médio mensal para cada variável meteorológica da Tabela 4.3, realizou-se a média de cada um, assumindo as mesmas como os valores meteorológicos médios mensais para o estado. O comportamento das variáveis meteorológicas médias do RS é apresentado nas Figuras 4.6 a 4.11 respectivamente.




Figura 4.6 – Velocidade média do vento no RS




Figura 4.7 – Direção média do vento no RS




Figura 4.8 – Precipitação média no RS




Figura 4.9 – Pressão atmosférica média no RS




Figura 4.10 – Temperatura máxima média e temperatura mínima média no RS




Figura 4.11 – Umidade relativa média no RS

Na Figura 4.12 apresenta-se um fluxograma de todos os processos descritos no módulo I.

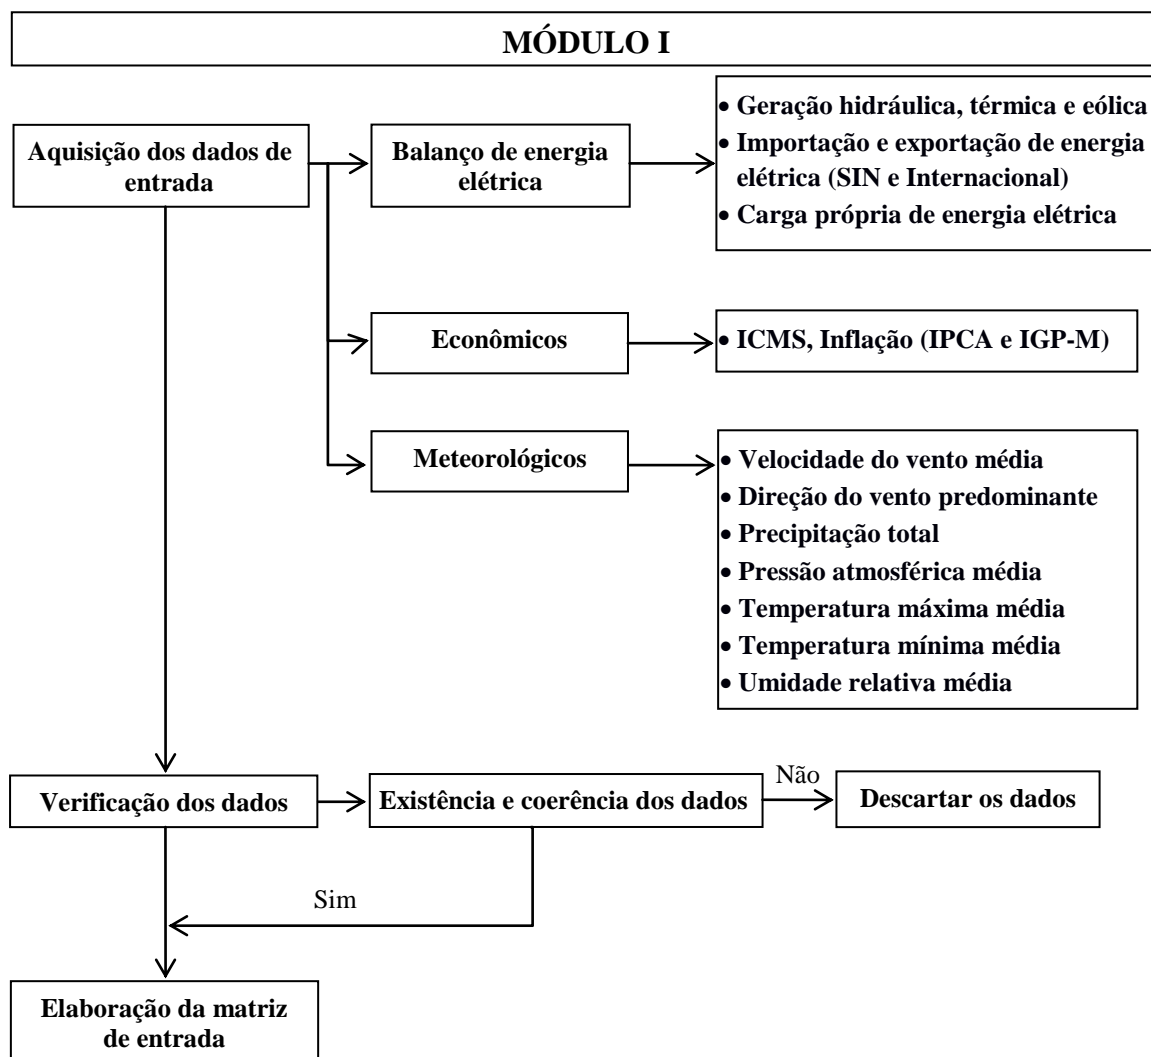


Figura 4.12 – Fluxograma do Módulo I

Os dados selecionados, (Figura 4.12), serão utilizados como entradas (*inputs*) na rede neural juntamente com mais um dado denominado “Tempo”, o qual refere-se aos meses do ano (janeiro =1, fevereiro=2,..., dezembro =12). O conjunto de dados será dividido em dois blocos, um para treinar a RNA e outro para realizar a previsão. Sendo assim, 75 amostras de 19 variáveis, correspondendo aos meses de janeiro de 2009 a março de 2015, foram separadas para treinar a RNA e 12 amostras das mesmas 19 variáveis, condizendo aos meses de abril de 2015 a março de 2016, foram alocadas para realizar a previsão. A variável cotendo os valores da geração de energia elétrica do RS

atribui-se o nome de “variável alvo” e na Figura 4.13 apresenta-se a ilustração como foram separadas as respectivas variáveis e seus intervalos.

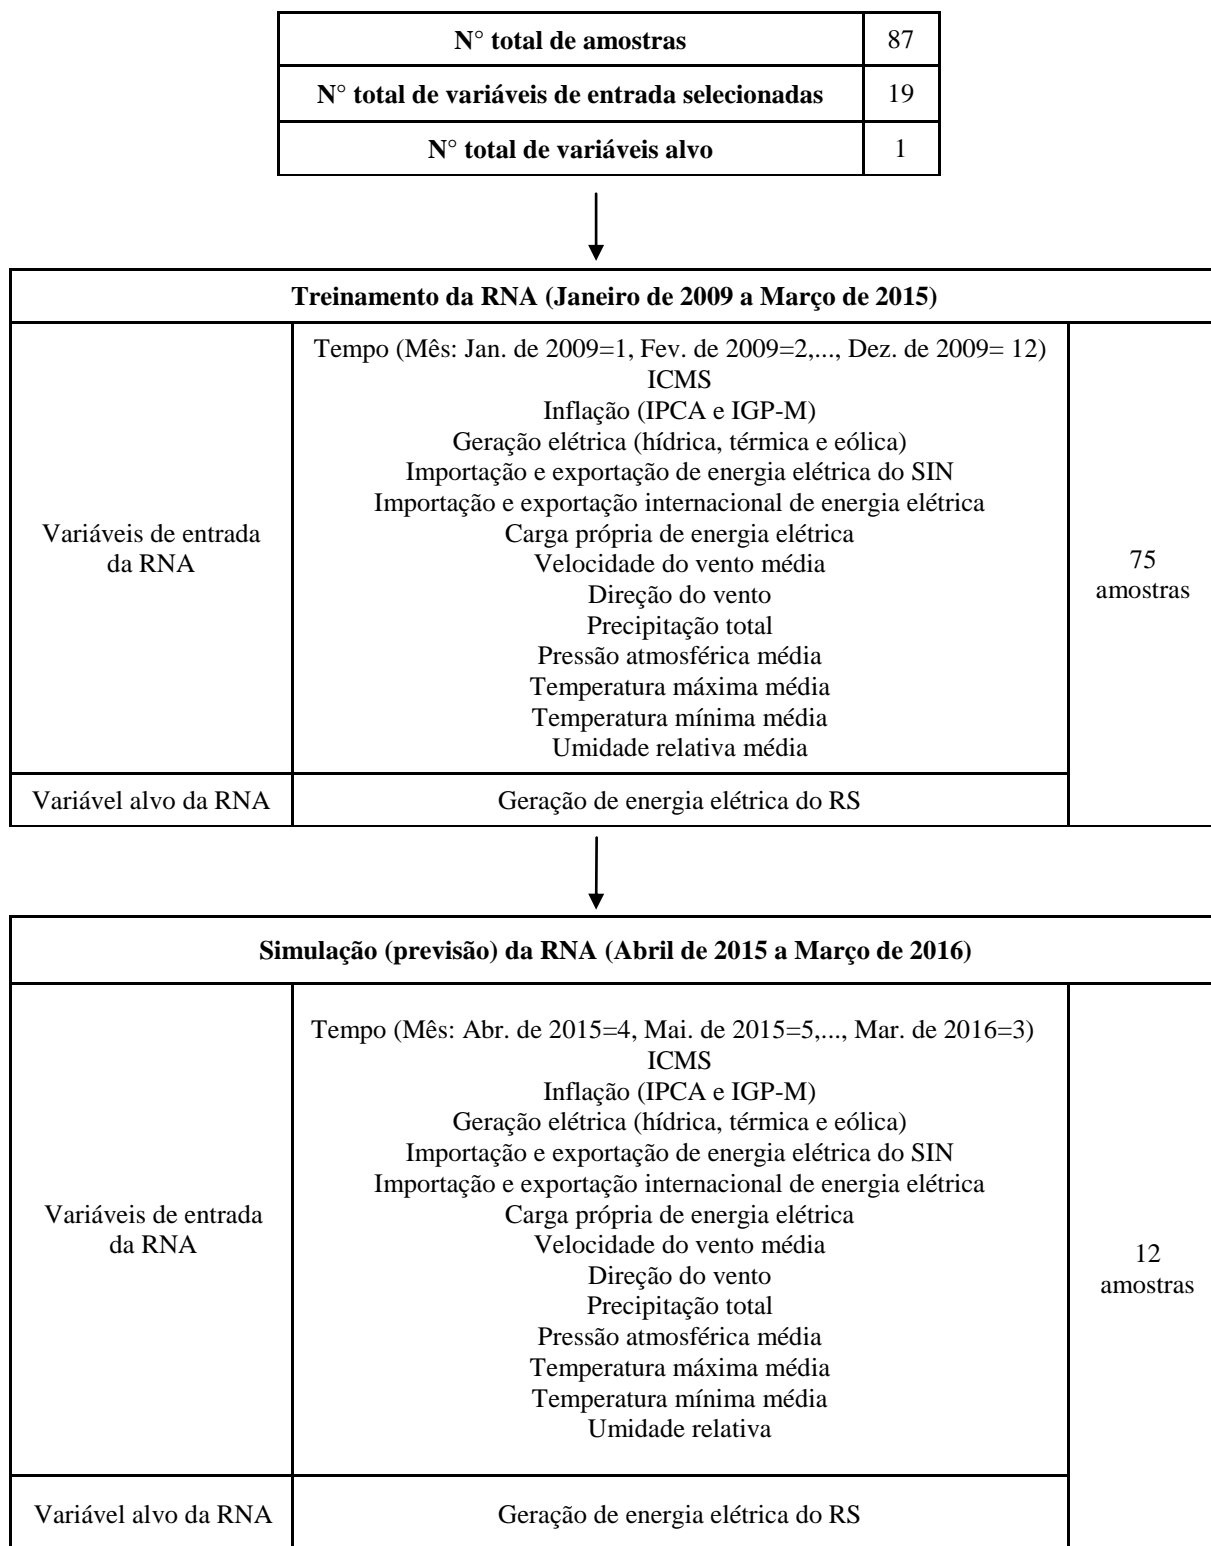


Figura 4.13 – Divisão das variáveis de entrada na RNA

Neste subcapítulo evidenciaram-se quais foram as variáveis selecionadas para a matriz de entrada e matriz alvo da RNA, bem como, sua divisão para treinamento e simulação (previsão). Todos os dados utilizados como entradas da RNA estão descritos no Anexo A em forma de tabelas, com objetivo de que os mesmos possam servir como base para elaboração de futuros trabalhos. Posteriormente, serão apresentadas as etapas referentes à criação, configuração, treinamento, teste e validação da RNA.

### 4.3 Módulo II: Criação, configuração, treinamento, teste e validação da RNA

O presente módulo emprega o *software* Matlab® 2012 para seu desenvolvimento, portanto a nomenclatura das variáveis ou comandos descritos nesta dissertação diz respeito ao mesmo. O programa apresenta uma série de comandos para criar, configurar e simular uma RNA, além de um *toolbox* (pacote) denominado *nntool* (*Neural Network Toolbox*) que serve exatamente para esta finalidade. Nesta dissertação optou-se por trabalhar com linhas de comando, visando criar um *script* que importe dados do Excel® e execute as simulações da RNA. Cabe ressaltar, que neste subcapítulo serão apresentados os principais comandos para criar o script, porém ao final deste capítulo (subcapítulo 4.4) encontra-se toda a programação desenvolvida, sendo a mesma comentada linha por linha sobre suas respectivas funções. Para realizar as simulações utilizou-se um *notebook* com processador core i3, 2.27 Gigahertz (GHz) com 4 *Gigabytes* (GB) de memória RAM (*Random Access Memory*).

Inicialmente, antes de criar uma RNA os dados selecionados para matriz de entrada devem ser importados para o Matlab®, opção esta realizada através do comando “*xlsread*”. Segundo Haykin, 2001, para uma melhor convergência e velocidade de processamento da rede, objetivando evitar um mau desempenho, todos os dados devem ser normalizados, sendo assim normalizou-se as variáveis de entrada individualmente entre o intervalo de -1 a 1. Para efetuar a normalização das variáveis empregou-se a função “*mapminmax*”, a qual, ao final das simulações pode ser utilizada novamente para desnormalizá-las.

As variáveis de entrada para o treinamento, que formam a matriz de entrada, contêm as 19 variáveis com 75 amostras (19 linhas por 75 colunas). A variável “alvo”, contendo os dados reais (observados) da geração de energia elétrica para o estado do RS possui 75 amostras, formando assim uma matriz com uma linha e 75 colunas. Essas

duas matrizes serão empregadas no treinamento da RNA, onde o conjunto de dados de entrada tem por objetivo reconhecer padrões (correlações) entre eles para tentar atingir um determinado objetivo, neste caso o alvo. Nesta etapa é importante ressaltar que será empregado um algoritmo de treinamento supervisionado, ou seja, serão comparados os resultados gerados pela RNA com o valores alvo, calculado o erro e o mesmo utiliza-se para calibrar os pesos sinápticos.

A matriz de entrada para a simulação (previsão) possui dimensões de 19 x 12 (19 variáveis contendo 12 amostras) e a variável alvo apresenta uma matriz com uma linha e 12 colunas, sendo estas doze amostras correspondendo ao período de um ano (abril de 2015 a março de 2016).

Depois de importado e normalizado todos os dados necessários, dá-se início a criação e configuração da RNA através do comando *net*. Neste comando escolhe-se o tipo de rede neural (*Feedforward Backpropagation*, neste caso corresponde ao comando *newff*), adiciona-se a matriz de entrada e alvo do treinamento, a quantidade de camadas e número de neurônios da camada oculta, as funções de transferência das respectivas camadas, a função de treinamento/aprendizagem e função de performance.

A configuração adequada de uma rede neural é de suma importância para que ocorra uma boa generalização, [Haykin, 2001]. Ainda conforme o autor, apenas uma única camada oculta é suficiente para efetuar uma previsão e a adição de mais camadas, em muitos casos, pode acarretar em uma má generalização da rede, fundamentando assim a escolha de uma camada oculta para a presente RNA.

Optou-se pela função de treinamento denominada *Gradient descent with momentum backpropagation (traingdm)*, sendo esta função responsável por atualizar os valores de peso e bias de acordo com o gradiente descendente do *momentum* (Equação (3.18)), [Matlab, 2016]. Segundo o tutorial do *software* e da literatura existente, esta função auxilia a rede a não convergir para mínimos locais (vide Figura 3.6), fazendo com que a rede ignore pequenos desvios na superfície de erro. Além disso, ela é altamente indicada como uma primeira escolha de algoritmo supervisionado, entretanto necessita de mais memória do que outros algoritmos. Os valores da taxa de aprendizagem  $\eta$  e *momentum* utilizados neste trabalho foram  $\eta=0,1$  e  $\beta=0,5$ , os quais segundo Haykin, 2001, ficam geralmente dentro de uma faixa de segurança, garantindo com que a rede “aprenda” e não decore os padrões.



Adotou-se como função de performance o erro quadrático médio (*mean square error* - MSE), o qual realiza o monitoramento do treinamento da rede enquanto ocorre a simulação e também tem por objetivo alcançar um erro mínimo estipulado pelo usuário, neste caso zero.

As funções de transferência ou ativação do tipo sigmoidal são ideais para problemas deste gênero, onde há duas ou mais camadas na RNA (entrada, camada intermediária e uma camada de saída, neste caso). Optou-se por escolher uma função de transferência que limitasse à amplitude do sinal de saída do neurônio para algum valor finito, dentro do intervalo normalizado entre -1 a 1, e também por apresentar os melhores resultados para entradas não lineares. Devido a estes fatores escolheu-se a função tangente hiperbólica sigmoidal (*tansig*).

Na divisão dos dados para treinamento, teste e validação particionou-se os mesmos em 50%, 25% e 25%, respectivamente. Conforme Braga et. al. 2007, para um número não muito significativo de amostras estes valores de divisão de amostras são adequados.

Uma consideração importante a ser feita refere-se à escolha do n° de neurônios da camada oculta ou escondida (*hidden layer*). Segundo Haykin, 2001, a seleção correta do número de neurônios nesta camada é de suma importância, pois um pequeno n° de neurônios pode não ser capaz de solucionar o problema na RNA, bem como um elevado n° pode causar problemas na convergência dos resultados e demora no tempo de processamento. Ainda segundo o autor, uma alternativa para esta problemática seria a variação do número de neurônios da camada escondida até um determinado valor, por exemplo, o dobro do n° de entradas, visando obter o menor MSE. Sendo assim, optou-se por utilizar esta metodologia, variando o n° de neurônios da camada intermediária em pares durante o treinamento da rede e na Tabela 4.6 apresenta-se a variação do n° de neurônios desta camada e o MSE registrado para cada caso.

Tabela 4.6 – Desempenho do treinamento da RNA em função do n° de neurônios da camada oculta TRAIGDM

| Caso | N° de neurônios da camada oculta | MSE      |
|------|----------------------------------|----------|
| 1    | 2                                | 0.002451 |
| 2    | 4                                | 0.004379 |
| 3    | 6                                | 0.001761 |

| Caso | Nº de neurônios da camada oculta | MSE      |
|------|----------------------------------|----------|
| 4    | 8                                | 0.004352 |
| 5    | 10                               | 0.002431 |
| 6    | 12                               | 0.014608 |
| 7    | 14                               | 0.001944 |
| 8    | 16                               | 0.001535 |
| 9    | 18                               | 0.004154 |
| 10   | 20                               | 0.004088 |
| 11   | 22                               | 0.002043 |
| 12   | 24                               | 0.014250 |
| 13   | 26                               | 0.022042 |
| 14   | 28                               | 0.001804 |
| 15   | 30                               | 0.017913 |
| 16   | 32                               | 0.001977 |
| 17   | 34                               | 0.005996 |
| 18   | 36                               | 0.019024 |
| 19   | 38                               | 0.001542 |

Analisando a Tabela 4.6, observa-se que o caso 8, o qual possui 16 neurônios na camada oculta apresentou o menor MSE, justificando assim a escolha do mesmo. A Figura 4.14, ilustra graficamente o comportamento do MSE em função da variação do nº de neurônios para os dados de treinamento.




Figura 4.14 – Desempenho do treinamento da RNA em função do nº de neurônios da camada oculta.

Ao final de todas as etapas, demonstra-se através da Tabela 4.7 as respectivas configurações selecionadas para a RNA.

Tabela 4.7 – Configuração da RNA

| <b>Configuração da RNA</b>           | <b>Atribuição</b>                  |
|--------------------------------------|------------------------------------|
| Nome da RNA                          | RN                                 |
| Tipo de RNA                          | <i>Feedforward Backpropagation</i> |
| Função de treinamento                | TRAINGDM                           |
| Função de performance                | MSE                                |
| Número de camadas ocultas            | 1                                  |
| Número de neurônios na camada oculta | 16                                 |
| Função de transferência              | TANSIG                             |

Os principais critérios de parada ou convergência da rede são selecionados pelo usuário e neste caso foram escolhidos o número máximo de ciclos (iterações) e o erro pretendido. Configurou-se um número máximo 1000 interações e erro pretendido 0 (zero), porém existem mais critérios de parada, tais como tempo de processamento, teste de checagem, valores de incremento e decremento de cada iteração, os quais podem ser verificados através do tutorial do software, [MATLAB, 2016].

Depois de realizados os treinamentos, testes e validações das redes demonstrou-se que com 16 neurônios na camada oculta a RNA apresenta o menor MSE, desta forma prosseguiu-se para as próximas etapas (simulação/previsão da RNA e processamento dos resultados). Como resultados do treinamento da RNA serão apresentados:

1. Desempenho da rede com 16 neurônios na camada oculta para os dados de treinamento, teste e validação;
2. Gráfico da regressão linear e coeficiente de correlação entre o resultado do conjunto de dados de treinamento, teste e validação da RNA com a matriz alvo;
3. Comparação gráfica dos valores preditos durante o treinamento para geração de energia elétrica e os valores reais (observados) para o mesmo período (matriz alvo).

Além disso, através das Equações (4.1), (4.2), (4.3) e (4.4), será demonstrado o Erro Absoluto (EA), o Erro Percentual Absoluto Médio (MAPE), o Desvio Absoluto

Médio (MAD - Mean Absolute Deviation) e o Erro Relativo Percentual (PRE - Percentage Relative Error) do treinamento e da simulação (previsão), respectivamente:

$$EA = a_t - y_t \quad (4.1)$$

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{a_t - y_t}{a_t} \right|}{N} * 100 \quad (4.2)$$

$$MAD = \frac{\sum_{t=1}^N |a_t - y_t|}{N} \quad (4.3)$$

$$PRE = \frac{a_t - y_t}{a_t} * 100 \quad (4.4)$$

onde N é o número de previsões realizadas,  $a_t$  é a saída desejada para a previsão índice “t” e  $y_t$ , a saída da simulação para a previsão índice “t”.

#### 4.4 Módulo III: Previsão da geração de energia elétrica e processamento dos resultados da previsão

Depois da RNA estar devidamente treinada, dá-se início a previsão da geração de energia elétrica do RS para o período de um ano (de abril de 2015 a março de 2016), utilizando o comando “*sim*”. Neste comando adiciona-se a rede treinada no módulo anterior e a matriz de entrada da simulação/previsão, que contem dados diferentes dos apresentados durante o treinamento, os quais, ao final, resultaram em uma matriz com os dados de previsão. A matriz de gerada pela simulação/previsão será comparada com a matriz alvo para o mesmo período, além disso, serão calculados os erros absolutos, MAPE, MAD, PRE (Equação (4.1), Equação (4.2), Equação (4.3), e Equação (4.4), respectivamente) e serão confrontados os resultados obtidos no presente trabalho com os encontrados na literatura para problemas semelhantes.

Conforme descrito no início do capítulo 4, demonstra-se através da Figura 4.15 o *script* desenvolvido para a presente metodologia.

```

clear all      % Limpar tudo
clc            % Limpa a janela de comando
%%
% Importando os dados do Excel
E= xlsread    ('C:\Users\MARCELO\Desktop\DISSERTAÇÃO\DADOS   ENTRADA
MATLAB.xlsx','B3:BX21');
A= xlsread    ('C:\Users\MARCELO\Desktop\DISSERTAÇÃO\DADOS   ENTRADA
MATLAB.xlsx','B23:BX23');
P= xlsread    ('C:\Users\MARCELO\Desktop\DISSERTAÇÃO\DADOS   ENTRADA
MATLAB.xlsx','B27:M45');
D= xlsread    ('C:\Users\MARCELO\Desktop\DISSERTAÇÃO\DADOS   ENTRADA
MATLAB.xlsx','B47:M47');

% E=entrada;      %Matriz de entrada da RNA - Variáveis selecionadas
% A=alvo;          %Alvo da matriz de entrada da RNA
% P=previsao;      %Matriz de simulação da RNA - Após o treinamento
% D=dadosreais;    %Dados reais (alvo) da previsão
%

%Normalização dos dados
[EN,PSE] = mapminmax(E);      %Normalização da matriz de entrada
[AN,PSA] = mapminmax(A);      %Normalização da matriz alvo
[PN,PSP] = mapminmax(P);      %Normalização da matriz de previsão
[DN,PSD] = mapminmax(D);      %Normalização da matriz dados reais

%%
%Inicialização da RNA
net=newff(EN,AN,[16],{'tansig','tansig'},'traingdm','mse');
%Criação da RNA do tipo FFB.
%[16] é o número de neurônios da camada intermediária (oculta).
%{'tansig' 'tansig'} são as funções de transferência da camada
intermediária e de saída, respectivamente.
%'traingdm' é a função de treinamento escolhida, neste caso a função
Gradient descent with momentum backpropagation.
%'mse' é a função de performance, a qual calcula o erro quadrático
médio da RNA.

net.trainParam.epochs = 1000; %Número máximo de épocas de treinamento
net.trainParam.goal = 0;      %Erro desejado
net.trainParam.lr = 0.1;      %Taxa de aprendizado
net.trainParam.mc = 0.5;      %Taxa de momento
view(net)                     %Visualizar uma a RNA

%Treinamento e simulação da RNA
net.divideParam.trainRatio = 50/100;      %50% dos dados de entrada
para o treinamento
net.divideParam.valRatio = 25/100;        %25% dos dados de entrada
para a validação
net.divideParam.testRatio = 25/100;       %25% dos dados de entrada
para o teste
[net,tr]= train(net, EN, AN);      %Treinamento da RNA
Saida = net(EN);                   %Resultado do treinamento da RNA normalizado
perf = perform(net,Saida,AN);      %Performance da RNA
figure, plotterhist(perf)          %Plotar o gráfico de performance
ST=sim(net, EN);                   %Simulação dos dados de treinamento
STD=mapminmax('reverse',ST,PSA)    %Resultado do treinamento da RNA
desnormalizado para gerar os resultados
Errot = A-STD;                     %Erro Absoluto do treinamento

%Resultados do teste
tIndT = tr.testInd;

```

```

tstTESTE = net(EN(:,tIndT));
tstPerformT = perform(net,AN(:,tIndT),tstTESTE)

%Resultados do validação
tVAL = tr.valInd;
tstVAL = net(EN(:,tVAL));
tstPerformV = perform(net,AN(:,tVAL),tstVAL)

%Resultados do treinamento
tTRAIN = tr.trainInd;
tstTR = net(EN(:,tTRAIN));
tstPerformTR= perform(net,AN(:,tTRAIN),tstTR)

trOut = Saida(tr.trainInd);
vOut = Saida(tr.valInd);
tsOut = Saida(tr.testInd);
trTarg = AN(tr.trainInd);
vTarg = AN(tr.valInd);
tsTarg = AN(tr.testInd);
plotregression(trTarg,trOut,'Train',vTarg,vOut,'Validation',tsTarg,ts
Out,'Testing') %Plotar gráficos de regressão

%Previsão dos dados de geração de energia elétrica do RS
PREV=sim(net, PN);
PREVD=mapminmax('reverse',PREV,PSD) %Resultado do treinamento da
RNA desnormalizado para gerar os resultados
Errorp = D - PREVD; % Erro absoluto desnormalizado

%Plotando resultados
figure, plot(A, 'r.-')
hold on
plot(STD,'k-')
figure, plot(D, 'r.-')
hold on
plot(PREVD,'k-')

%Plotando os erros absolutos do treinamento (Error) e previsão(Errorp)
figure, ploterrhist(Error)
figure, ploterrhist(Errorp)

%MAPE da previsão
MAPE=( (sum(abs((D-PREVD)./D)))./12).*100
%MAD da previsão
MAD=( (sum(abs((D-PREVD))))./12)
%PRE da previsão
PRE=((D-PREVD)./D).*100

```

Figura 4.15 – Script desenvolvido no Matlab®.

## 5 RESULTADOS E DISCUSSÕES

Utilizando informações passadas referentes à geração de energia elétrica do RS, dados meteorológicos do estado e dados econômicos do estado e do país, objetivou-se realizar a previsão da geração de energia elétrica do RS para o período de um ano (abril de 2015 a março de 2016) empregado RNA's. É importante ressaltar novamente que, as informações técnicas disponibilizadas pela CEEE e que dizem respeito ao balanço mensal de energia elétrica do estado não se encontram disponíveis via meios de pesquisa convencionais (internet, livros, revistas, entre outros). Desta forma, a apresentação das informações técnicas, com estes detalhamentos e intervalo de tempo (mês) podem ser consideradas inéditas, bem como, o conjunto de dados pertencentes à matriz de entrada.

Neste capítulo serão apresentados e discutidos os resultados gerados através do *script* demonstrado na Figura 4.15. Inicialmente, dois dos objetivos específicos já foram alcançados, sendo o primeiro deles a elaboração e disponibilização de um banco de dados, que contenham algumas informações referentes ao balanço mensal de energia elétrica, dados meteorológicos e econômicos do estado do RS, além de dados econômicos do país. Este objetivo encontra-se apresentado no Anexo A (Banco de dados - Matriz de entrada e matriz alvo da RNA) desta dissertação em formato de tabelas, descrevendo os dados usados para o treinamento e posteriormente previsão da RNA. Espera-se que estas informações sejam difundidas e possam ser utilizadas em estudos futuros, pois um dos grandes problemas encontrados na elaboração deste trabalho refere-se à obtenção de dados específicos sobre o balanço de energia elétrica.

O segundo objetivo específico diz respeito a identificar e selecionar o número de neurônios da camada intermediária da RNA, durante a configuração e criação da mesma, baseando-se na busca do menor erro quadrático médio (*Mean Square Error - MSE*). Atingiu-se este objetivo ainda na metodologia, onde através da Tabela 4.6 e da Fig 4.14, no qual foi possível demonstrar que a estrutura da RNA com 16 neurônios na camada intermediária registrou o menor MSE e por isso selecionou-se a mesma. Evidenciou-se este objetivo no capítulo 4 para que fosse possível dar sequência no desenvolvimento do *script* (Figura 4.15) e posteriormente a simulação da rede, justificando assim o motivo pelo qual se apresentou este resultado na seção anterior.

Conforme a Figura 4.14, o número de neurônios da camada oculta que apresentou o menor MSE foi 16, convergindo com mil épocas, um dos critérios de parada, e através da Figura 5.1 é possível analisar o comportamento dos dados de treinamento, teste e validação para simulação.




Figura 5.1 – Performance dos dados treinamento, teste e validação da RNA

Observa-se em na Figura 5.1 que tanto o teste como validação estabilizaram antes do treinamento, isso ocorre devido à quantidade de amostras dos mesmos ser a metade da quantidade de amostras do treinamento. Nas primeiras épocas observa-se que a validação convergiu para um mínimo local, porém no decorrer da simulação constatou-se que foi possível sair desta região, não mais registrando comportamentos deste tipo. Verificou-se também que na 600ª época a rede começou a estabilizar definitivamente, tendo pequenas variações até atingir o critério de parada (1000 épocas). O teste apresentou comportamento semelhante à validação, porém não registrou-se a ocorrência de um mínimo local na mesma. Por fim, na 1000ª época o treinamento atingiu o menor MSE, no valor de 0.001535, e através da combinação deste três conjuntos (treinamento, teste e validação) pode-se concluir que a rede apresentou uma boa generalização, conforme é esperado para que se possam realizar as simulações seguintes.



O coeficiente de correlação (R) e a regressão linear entre os resultados simulados (Saída) e observados (Alvo), para o conjunto de dados de treinamento, teste e validação e um conjunto contendo todos (Todos = treinamento + teste + validação), são ilustrados nas Figuras 5.2, 5.3, 5.4 e 5.5, respectivamente.




Figura 5.2 – Gráfico de regressão entre a saída e alvo para conjunto de dados de treinamento da RNA




Figura 5.3 – Gráfico de regressão entre a saída e alvo para o conjunto de dados teste da RNA




Figura 5.4 – Gráfico de regressão entre a saída e alvo para o conjunto de validação da RNA




Figura 5.5 – Gráfico de regressão entre a saída e alvo de todos os conjuntos RNA (todos = treinamento + teste + validação)

Nas Figuras 5.2 a 5.5 apresenta-se a direita do eixo Y a equação da regressão linear para cada respectivo gráfico. O primeiro termo da corresponde ao declive

(inclinação da reta de ajuste) e o segundo a interceptação com o eixo Y, evidenciando qual a melhor regressão linear (equação) que relaciona os alvos com saídas de rede. O valor do coeficiente de correlação ( $R$ ) é uma medida de quão bem a variação na saída é explicada pelos alvos. Se esse número for igual a 1, então há uma perfeita correlação entre alvos e saídas. Observa-se que os valores de  $R$  foram relativamente altos para o treinamento (0,99747) e teste (0,95915) e um pouco menores para a validação (0,89056), isso demonstra que houve um bom ajuste entre as saídas e os alvos. Deve-se destacar também o valor de  $R$  considerando todos os dados (0,97292), estando muito próximo de 1 e confirmando um bom ajuste. Desta forma confirma-se a influência das variáveis selecionadas na matriz de entrada, a existência de padrões de reconhecimento entre elas e a boa generalização da rede.

Na Figura 5.6 demonstra-se o resultado do treinamento da RNA através da comparação entre a geração de energia elétrica utilizando os dados de treinamento (Simulado) e os dados reais (Observado).




Figura 5.6 – Resultado do treinamento da RNA: Geração de energia elétrica em função do tempo

Pode-se verificar através da Figura 5.6 que o resultado observado (valor real) e simulado ficou bem próximo, conforme era esperado, pois os valores do coeficiente de correlação foram próximos a 1. As maiores diferenças registradas foram nos “picos” (pontos máximos) do mesmo, isso ocorre pelo fato de não ter sido apresentado à rede muitos valores fora do “padrão”, ou seja, comportamentos atípicos da geração de energia elétrica ou pouca relação entre a entrada e saída para esses pontos.

Nas Figuras 5.7 e 5.8 são expressos o histograma de erro absoluto e o histograma relativo percentual, respectivamente.




Figura 5.7 – Histograma de erro absoluto do treinamento da RNA

A Figura 5.7 demonstra que dos 75 erros absolutos, 52 obtiveram valores entre  $\pm 85$  MW médio, ou seja, aproximadamente 70% do total de erros absolutos.




Figura 5.8 – Histograma de erro relativo percentual do treinamento da RNA

A Figura 5.8 apresentou os erros relativos percentuais, os quais 47 permaneceram dentro de uma faixa de erro em torno 5%, equivalendo a 63% do total de erros relativos. Os erros MAPE (Equação (4.2)) e MAD (Equação (4.3)) obtidos através da comparação entre o valor observado e simulado para o treinamento da RNA foram de 5,36% e 75,82 MW médio, respectivamente.

Os resultados descritos até o presente momento dizem respeito á capacidade de generalização da rede, regressão linear e coeficiente de correlação entre a saída e valor alvo e por fim, o resultado do treinamento da RNA. Na sequência apresentar-se-á, na Figura 5.9, o resultado da previsão de geração de energia elétrica para o período de abril de 2015 a março de 2016 (12 meses).




Figura 5.9 – Previsão da RNA: Geração de energia elétrica em função do tempo

Analisando a Figura 5.9 pode-se constatar que a previsão apresentou comportamento semelhante e valores próximos comparado com os dados observados. Percebe-se novamente que, nos pontos observados onde se registrou os valores máximos de geração de energia elétrica a RNA apresentou os maiores erros. Este mesmo tipo de comportamento aconteceu durante o treinamento e duas causas possíveis para o acontecido pode estar vinculada a quantidade de amostras (número pequeno) ou o conjunto de dados de entrada para cada respectivo ponto de máximo (alvo) não possibilitou a rede extrair e reconhecer padrões entre os mesmos.

Pode-se observar que durante o treinamento, o valor máximo observado para a geração de energia elétrica foi em torno de 2500 MW médio, porém na previsão o valor máximo registrado foi de 2700 MW médio, ou seja, durante o treinamento da RNA não foi apresentado um comportamento com essas magnitudes (ponto atípico), fazendo com que a rede não conseguisse extrair um padrão de reconhecimento adequado e provocando um erro elevado. Nas Figuras 5.10 e 5.11 são expressos os gráficos do erro absoluto e do relativo percentual, respectivamente.




Figura 5.10 – Erro absoluto da previsão da RNA




Figura 5.11 – Erro relativo percentual da previsão da RNA

A Figura 5.10 demonstra que dos 12 erros absolutos, 6 obtiveram valores na faixa entre 0 e  $\pm 100$  MW médio (linha tracejada verde), ou seja, 50% do total de erros absolutos. Dos 6 erros absolutos restantes, 3 ficaram entre a faixa de  $\pm 100$  MW médio e  $\pm 200$  MW médio (linha pontilhada amarela) e os demais com valores superiores a  $\pm 200$  MW médio.

Na Figura 5.11 apresentaram-se os erros relativos percentuais, dos quais 7 permaneceram dentro de uma faixa de erro em torno  $\pm 5\%$ , equivalendo a aproximadamente 60% do total de erros relativos. Além disso, 3 erros apresentaram valores entre a faixa de  $\pm 5\%$  e  $\pm 10\%$  e 2 registraram erros superiores a  $\pm 10\%$ . Os erros MAPE (Equação (4.2)) e MAD (Equação (4.3)) obtidos através da comparação entre o valor observado e simulado para a previsão da RNA foram de 5,86% e 134,15 MW médio, respectivamente. A Tabela 5.1 apresenta um resumo dos erros MAPE e MAD obtidos nesta dissertação.

Tabela 5.1 – Tabela de erros MAPE e MAD para o treinamento e previsão

| Dados       | MAPE (%) | MAD (MW médio) |
|-------------|----------|----------------|
| Treinamento | 5,36     | 75,82          |
| Previsão    | 5,86     | 134,15         |

Os erros evidenciados na Tabela 5.1 apresentaram valores relativamente baixos considerando um horizonte de médio prazo (um ano) e na ordem dos encontrados na literatura.

Na Tabela 5.2 apresenta-se o erro (MAPE) encontrado em alguns trabalhos relevantes da literatura para previsões no setor energético (demanda e geração de energia elétrica), nos quais os autores aplicaram a metodologia das RNA's para horizontes distintos (curtíssimo, curto, médio e longo prazo). Destaca-se que todos estes trabalhos estão evidenciados na seção 3.5, descrevendo as variáveis que foram usadas em cada modelo, algumas especificações técnicas e metodológicas, bem como seu objetivo principal.



Tabela 5.2 – Erros encontrados na literatura para previsão no setor energético utilizando RNA's

| Autor(es)                 | Horizonte de previsão | Tipo de erro    | Valor do erro         |
|---------------------------|-----------------------|-----------------|-----------------------|
| Charytoniuk e Chen, 2000  | Curtíssimo prazo      | MAPE            | Entre 0,66% e 1,05%   |
| Beccali et al. 2004       | Curto prazo           |                 | Entre 0,09% e 3,81%   |
| Bashir e Hawary, 2009     |                       |                 | 2%                    |
| Abdel-Aal, 2008           | Médio prazo           | MAPE            | 3,2% e 3,8%           |
| Romera et al., 2007       |                       |                 | 2% *e 7 %*            |
| Yona et al., 2007         |                       |                 | Em torno de 12%       |
| Methaprayoon et al., 2007 |                       | Erro percentual | Entre 3,07% e 5,75%   |
| Uzlu et al.,2014          | Longo prazo           | MAPE            | 4,5599% * e 5,202% ** |
| Khoa et al., 2004         |                       |                 | 3%                    |

\*Melhor caso

\*\*Pior caso

Os diferentes autores aplicaram em seus trabalhos a técnica de RNA's (sozinhas ou em parceria com outros modelos) para realizar previsões de demanda de energia elétrica em alguns trabalhos e outros de geração de energia elétrica oriunda de alguma fonte (solar, hídrica, eólica). Os resultados obtidos para os trabalhos citados na Tabela 5.2 apresentaram erros relativamente baixos, constatando assim a eficácia e popularidade do método para este tipo de problemática. Comparando os resultados obtidos no presente trabalho com os encontrados na literatura, sugere-se que os mesmos são equivalentes comparando a ordem de grandeza dos erros para um horizonte de previsão de médio prazo, apesar de cada estudo empregar diferentes entradas para suas respectivas RNA's.

## 6 CONCLUSÕES

O presente trabalho teve como objetivo principal realizar a previsão da geração de energia elétrica em um horizonte de médio prazo (um ano) para o estado do Rio Grande do Sul empregando a técnica de redes neurais artificiais. A partir dos trabalhos encontrados na literatura e evidenciados nesta dissertação foi possível perceber que diversos autores utilizam diferentes variáveis para realizar suas previsões em horizontes distintos (curtíssimo, curto, médio e longo prazo). Tais trabalhos extraem informações de dados que possuem relação com a geração e demanda de energia elétrica para cada horizonte específico, como fatores meteorológicos, econômicos e dados passados referentes à energia elétrica (geração e demanda, por exemplo).

Com base nestas informações optou-se por fazer o uso de dados passados do balanço de energia elétrica do RS (geração de energia elétrica por fonte, importação e exportação de energia elétrica do SIN e internacional e carga própria de energia elétrica), dados socioeconômicos (estadual e nacional) e meteorológicos do estado para abastecer a matriz de entrada da RNA. As informações contidas na matriz de entrada possuíram frequência mensal, desde janeiro de 2009 a março de 2016, porém destaca-se que nos dados meteorológicos foram feitas médias das variáveis (velocidade do vento média, direção do vento predominante, precipitação total, pressão atmosférica média, temperatura máxima e mínima média e umidade relativa média) das estações cadastradas do BDMEP que continham todos os dados. Realizou-se a separação dos dados para treinamento (compreende o conjunto de treinamento, teste e validação) e previsão, os quais de janeiro de 2009 a março de 2015 foram utilizados para o treinamento da rede e de abril de 2015 a março de 2016 para realizar a previsão.

De posse destes dados iniciou-se a criação e configuração da RNA, sendo esta uma rede do tipo MLP com algoritmo de aprendizado do tipo *backpropagation*. A comprovação de uma configuração adequada deu-se através dos resultados do treinamento da rede, os quais apresentaram uma boa generalização tanto para o conjunto de treinamento quanto para o conjunto de teste e validação. A regressão linear entre os resultados gerados durante esta etapa com os dados observados (alvo) apresentou um alto coeficiente de correlação, demonstrando e comprovando a capacidade de generalização da rede. Além disso, a comparação entre o valor simulado e observado

pela rede após o treinamento apresentou resultados satisfatórios, como um MAPE de 5,36 % e um MAD de 75,82 MW médio.

A previsão da geração de energia elétrica realizou-se somente depois de verificar a ocorrência de um treinamento adequado da rede, o qual pode ser confirmado através dos resultados mencionados anteriormente. Desta forma, procedeu-se com a previsão propriamente dita, a qual resultou em um MAPE de 5,86% e um MAD de 134,85 MW médio. Além disso, comparou-se o MAPE obtido neste trabalho com os encontrados na literatura, evidenciando que o valor registrado se encontra na faixa de valores obtidos pelos autores estudados nesta dissertação para um horizonte de médio prazo.

Uma observação importante a ser destacada é que para um horizonte de médio prazo, com frequência mensal, existem poucos trabalhos na literatura que utilizem a mesma combinação de dados de entrada deste estudo, demonstrando que o emprego dos mesmos pode ser benéfico para produzir resultados com erros cada vez menores. Outra consideração significativa refere-se ao número de amostras do presente trabalho, no qual um número maior de observações poderia proporcionar um erro menor e uma maior quantidade de extrações das características entre as variáveis de entrada.

Em suma, a técnica de redes neurais artificiais se mostrou adequada não somente para a previsão de demanda de energia elétrica, como se observa na maioria dos trabalhos, mas também para a previsão de geração de energia empregando informações relativas a dados passados o setor elétrico, dados econômicos e meteorológicos de uma determinada região.

## 6.1 Considerações Futuras

Em trabalhos futuros podem-se considerar os seguintes temas a serem abordados:

- Analisar qual variável de entrada possui maior influência no objetivo desejado (previsão da geração de energia elétrica), uma vez que nas redes neurais os pesos sinápticos não possuem este propósito. Dois métodos que podem ser empregados para esta finalidade são: o K-ésimo Vizinho mais Próximo (KNN -  $K^{th}$  *Nearest Neighbor*) e o Modelagem Suave Independente por Analogia de Classe (SIMCA - *Soft Independent Modeling of Class Analogy*). Ambos os métodos baseiam-se na

hipótese de que quanto mais parecidas entre si forem as amostras, mais próximas elas estarão no espaço multidimensional gerado pelas variáveis.

- Diminuir a quantidade de variáveis da matriz de entrada e analisar qual o impacto no objetivo desejado, visando obter uma RNA mais simplificada sem perder a qualidade nos resultados.
- Dividir a matriz de entrada por tema (energia elétrica, economia e meteorologia) e criar uma RNA para cada área, realizar o treinamento e previsão, e por fim, comparar com os resultados obtidos nesta dissertação.
- Realizar o mesmo estudo utilizando as mesmas variáveis, porém empregado o método ANFIS (*Adaptive Neuro-fuzzy Inference System*) e comparar os resultados para cada uma das técnicas.
- Propor cenários futuros baseados nos empreendimentos em construção e construção não iniciada, visando obter uma estimativa da geração de energia elétrica no longo prazo (período superior a um ano).

## REFERÊNCIAS BIBLIOGRÁFICAS

Abdel-Aal, R. E. Univariate Modeling and Forecasting of Monthly Energy Demand Time Series Using Abductive and Neural Networks. **Computers & Industrial Engineering**, v. 54, p. 903-917, 2007.

ANA - Agência Nacional de Águas: Encarte especial sobre a crise hídrica - conjuntura dos recursos hídricos no Brasil (informe 2014), 2015. Disponível em: <<http://conjuntura.ana.gov.br/docs/crisehidrica.pdf>>. Acessado em: 23 de mai. 2016.

Andrade Filho, R. T. **Aplicação de Redes Neurais no Controle de Tuberculose Bovina**. – Rio de Janeiro: UFRJ/COPPE, 2016.

Andrade, L. M. **Abordagem Neurofuzzy Para Previsão de Demanda de Energia Elétrica no Curtíssimo Prazo**. Tese de Doutorado. Universidade de São Paulo, 2010.

Andreolli, I. Previsão de vazão em tempo real no rio Uruguai com base na previsão meteorológica. Dissertação de Mestrado. Universidade Federal do Rio Grande do Sul, 2003.

ANEELa – Agência Nacional de Energia Elétrica: Capacidade de geração no estado. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/ResumoEstadual/CapacidadeEstado.cfm>>. Acesso em: 10 dez. 2016

ANEELb – Agência Nacional de Energia Elétrica: Central Geradora Solar Fotovoltaica. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/ResumoEstadual/GeracaoTipoFase.asp>>. Acesso em: 18 set. 2016

Atlas Eólico do Rio Grande do Sul - Elaborado por Camargo Schubert Engenheiros Associados e Eletrosul Centrais Elétricas S.A.; Porto Alegre: SDPI: AGDI, 2014.

Atlas Socioeconômico do RS. Economia. Disponível em: <[http://www.atlassocioeconomico.rs.gov.br/conteudo.asp?cod\\_menu\\_filho=818&cod\\_menu=817&tipo\\_menu=ECONOMIA&cod\\_conteudo=1468](http://www.atlassocioeconomico.rs.gov.br/conteudo.asp?cod_menu_filho=818&cod_menu=817&tipo_menu=ECONOMIA&cod_conteudo=1468)>. Acesso em: 23 de out. de 2016

Balanço Energético Nacional (BEN) 2016: Ano base 2015 / **Empresa de Pesquisa Energética**. – Rio de Janeiro : EPE, 2016. 292 p.

Bardelin, C. E. A. **Os efeitos do racionamento de energia elétrica ocorrido no Brasil em 2001 e 2002 com ênfase no consumo de energia elétrica**. Tese de Doutorado. Universidade de São Paulo, 2004

Barreto, Jorge Muniz. Inteligência Artificial no limiar do século XXI. **Florianópolis: PPP edições**, v. 97, 1999.

Bashir, Z. A.; El-Hawary, M. E. Applying Wavelets to Short-Term Load Forecasting Using PSO-Based Neural Networks, **IEEE Transactions On Power Systems**, v. 24, p. 20-27, 2009.

BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa. Disponível em: <<http://www.inmet.gov.br/projetos/rede/pesquisa/>>. Acesso em: 15 de abr. 2016.

Beccali, M.; Cellura, M.; Lo Brano, V.; Marvuglia, A. Forecasting Daily Urban Electric Load Profiles using Artificial Neural Networks, **Energy Conversion and Management**, v. 45, p. 2879-2900, 2004.

BERS – Balanço Energético do Rio Grande do Sul, 2015 . Disponível em: <[http://www.cee.com.br/pportal/cee/Archives/Upload/Balanco\\_Energetico\\_RS\\_2015\\_base\\_2014\\_61962.pdf](http://www.cee.com.br/pportal/cee/Archives/Upload/Balanco_Energetico_RS_2015_base_2014_61962.pdf)> Acesso em: 23 jun. de 2016.

Bhattacharya, M.; Paramati, S. R.; Ozturk, I.; Bhattacharya, S. The effect of renewable energy consumption on economic growth: Evidence from top 38 countries. **Applied Energy**, v. 162, p. 733-741, 2016.

Bishop, Christopher M. Pattern recognition. **Machine Learning**, v. 128, p. 1-58, 2006.

Boser, B. E.; Guyon, I. M.; Vapnik, V. N. A training algorithm for optimal margin classifiers. **Proceedings of the fifth annual workshop on Computational learning theory**. p. 144-152. ACM, 1992.

Braga, A. P.; Carvalho A. C. P. F.; Ludermir, T. B. **Fundamentos de redes neurais artificiais**. Rio de Janeiro: 11ª Escola de Computação/Universidade Federal do Rio de Janeiro. 246p., 1998.

Braga, A. P.; de Carvalho, A. P. L. F.; Ludermir, T.B. **Redes neurais artificiais: teoria e aplicações**. LTC Editora, 2007.

CEEE – Companhia Estadual de Energia Elétrica. Consumo de energia elétrica, 2014. Disponível em: <<http://www.cee.com.br/pportal/cee/component/Controller.aspx?CC=63500>>. Acesso em: 28 de ago. de 2016

Charytoniuk, W.; Chen, M. S. Very short-term load forecasting using artificial neural networks. **IEEE transactions on Power Systems**, v. 15, n. 1, p. 263-268, 2000.

Cybenko, G. **Continuous valued neural networks with two hidden layers are sufficient**. Medford, MA: Department of Computer Science, Tufts University, 1988. Technical Report.

da Silva, R. C.; de Marchi Neto, I.; Seifert, S. S. Electricity supply security and the future role of renewable energy sources in Brazil. **Renewable and Sustainable Energy Reviews**, v. 59, p. 328-341, 2016.

Eletrobras. NEWAVE - Modelo de Planejamento da Operação de Sistemas Hidrotérmicos Interligados de Longo e Médio Prazo. Disponível em:<

<http://www.cepel.br/produtos/newave-modelo-de-planejamento-da-operacao-de-sistema-s-hidrotermicos-interligados-de-longo-e-medio-prazo.htm>>. Acesso em: 2 set. 2016

EPE – Empresa de Pesquisa Energética. Consumo mensal de energia elétrica por classe (regiões e subsistemas) – 2004-2016. Disponível em: <[http://www.epe.gov.br/mmercado/Paginas/Consumomensaldeenergiael%C3%A9trica%20por%20classe\(regi%C3%B5es%20e%20subsistemas\)%E2%80%932011-2012.aspx](http://www.epe.gov.br/mmercado/Paginas/Consumomensaldeenergiael%C3%A9trica%20por%20classe(regi%C3%B5es%20e%20subsistemas)%E2%80%932011-2012.aspx)>. Acesso em: 11 out. 2016.

Fiorin, D. V.; Schuch, N. J. F. R.; Pereira, E. B. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, v. 33, n. 1, p. 1309, 2011.

Galvão, J.; Bermann, C. Crise hídrica e energia: conflitos no uso múltiplo das águas. **Estudos Avançados**, v. 29, n. 84, p. 43-68, 2015.

Gomes, A. J. P.; Cruz, P. R.; Borges, L. P. **Recursos minerais energéticos: carvão e urânio**. Geologia, tectônica e recursos minerais do Brasil, Brasília: CPRM, p. 577-601, 2003.

GRUPO CEEE. Balanço Energético do Estado do Rio Grande do Sul 2005/2006/2007. Porto Alegre, Grupo CEEE / Secretaria de Infra-Estrutura e Logística do Rio Grande do Sul. 240p., 2008.

Guarnieri, R. A. Emprego de redes neurais artificiais e regressão linear múltipla no refinamento das previsões de radiação solar do modelo Eta. **Instituto Nacional de Pesquisas Espaciais**, 171pp, 2006.

Günay, M. E. Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: Case of Turkey. **Energy Policy**, v. 90, p. 92-101, 2016.

HAYKIN, S. A comprehensive foundation. **Neural Networks**, v. 2, n. 2004, p. 41, 2004.

Haykin, S. **Redes neurais: princípios e prática**, 2ª. ed. Porto Alegre: Bookman Companhia Editora, 2001. 900p.

Hebb, D. O. **The organization of behavior**. Wiley: New York, NY, USA, 1949.

Hopfield, J. J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the national academy of sciences**, v. 79, n. 8, p. 2554-2558, 1982.

IBGE - Instituto Brasileiro de Geografia e Estatística. Sistema Nacional de Índices de Preços ao Consumidor. Estruturas de Ponderação a Partir da Pesquisa de Orçamentos Familiares 2008-2009. Rio de Janeiro. 2014.

INMET - Instituto Nacional de Meteorologia. Banco de Dados Meteorológicos para Ensino e Pesquisa. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>. Acesso em: 15 de abr. 2016.

IPEADATA - Instituto de Pesquisa Econômica Aplicada: Ipeadata macroeconômico. Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>>. Acessado em: 04 de maio 2016.

Khoa, T. Q. D.; Phuong, L. M.; Binh, P. T. T.; Lien, N. T. H. Application of Wavelet and Neural Network to Long-Term Load Forecasting. **International Conference on Power System Technology**. v. 1, p. 840-844. 2004.

Mamlook, R.; Badran, O.; Abdulhadi, E. A Fuzzy Inference Model for Short-Term Load Forecasting, **Energy Policy**, v. 37, p. 1239-1248, 2009.

Marques Junior, L. S.; Oliveira, C.A. **As elasticidades de curto e longo prazo do ICMS no RS**. Textos para Discussão FEE N° 117 Secretaria do Planejamento, Gestão e Participação Cidadã Fundação de Economia e Estatística Siegfried Emanuel Heuser. Porto Alegre, janeiro de 2014.

Matlab. Gradient descent with momentum backpropagation (traingdm). Disponível em: < [http://www.mathworks.com/help/nnet/ref/traingdm.html?searchHighlight=traingdm&s\\_tid=doc\\_srchtile](http://www.mathworks.com/help/nnet/ref/traingdm.html?searchHighlight=traingdm&s_tid=doc_srchtile)>. Acesso em: 27 de Maio 2016.

Mcculloch, W. S.; Pitts, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

Melo, A. P. **Desenvolvimento de um método para estimar o consumo de energia de edificações comerciais através da aplicação de redes neurais**. Tese de Doutorado. Universidade Federal de Santa Catarina, 2012.

Mello, J. S.; Meza, L. A.; Gomes, E. G.; Fernandes, A. J. S.; Neto, L. B. Estudo não paramétrico da relação entre consumo de energia, renda e temperatura. **IEEE Latin America Transactions**, v. 6, p. 153-161, 2008.

Methaprayoon, K.; Yingvivatanapong, C.; Lee, W. J.; Liao, J. R. An integration of ANN wind power estimation into unit commitment considering the forecasting uncertainty. **IEEE Transactions on Industry Applications**, v. 43, n. 6, p. 1441-1448, 2007.

Ministério de Minas e Energia (MME). Intercâmbio de energia. Disponível em: <[http://www.mme.gov.br/web/guest/pagina-inicial/manchete/-/asset\\_publisher/neRB8QmDsbU0/content/mme-regulamenta-importacao-de-energia-da-argentina-e-uruguai](http://www.mme.gov.br/web/guest/pagina-inicial/manchete/-/asset_publisher/neRB8QmDsbU0/content/mme-regulamenta-importacao-de-energia-da-argentina-e-uruguai)>. Acesso em: 8 de ago. 2016.

Minsky, M.; Papert, S. **Perceptrons: an introduction to computational geometry**. Massachusetts: MIT Press, 1969.

Morettin, P. A.; Toloi, C. **Análise de séries temporais**. Blucher, 2006.

Ocal, O.; Aslan, A. Renewable energy consumption–economic growth nexus in Turkey. **Renewable and Sustainable Energy Reviews**, v. 28, p. 494-499, 2013.



Oliveira, P.S.S. ; Menciondo, R. Métodos de Previsão de Consumo de Energia Elétrica: Regressão e Redes Neurais Artificiais. **Congresso Nacional de Excelência em Gestão**, Rio de Janeiro, 2014.

Osório, F. S.; Bittencourt, J. R.; Osório, J. R. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. **I Workshop de inteligência artificial**. 2000.

Pádua, A.B.; Carvalho, A. P. L. F.; Ludermir, T. B. **Redes neurais artificiais: teoria e aplicações**. LTC Editora, 2007.

Plano Decenal de Expansão de Energia 2024 / Ministério de Minas e Energia. **Empresa de Pesquisa Energética**. Brasília: MME/EPE, 2015

Plano Energético do RS 2016/2025. Secretaria de Minas e Energia. Disponível em: <<http://minasenergia.rs.gov.br/plano-energetico>>. Acesso em: 10 de jan. 2017.

Prodanov, C. C.; Freitas, E. C. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico-2ª Edição**. Editora Feevale, 2013.

Rahman, S.; Hazim, O. A Generalized Knowledge-Based Short-Term Load Forecasting Technique. **IEEE Transactions on Power Systems**, v. 8, p. 508-514, 1993.

Raizer, K.; Idagawa, H. S.; de Oliveira Nóbrega, E. G.; Ferreira, L. O. S. Training and Applying a Feedforward Multilayer Neural Network in GPU. In **Proceedings of the 30th Iberian-Latin-American Congress on Computational Methods in Engineering**. 2009.

Reidmiller, M. Advanced supervised learning in multi-layer perceptrons - from backpropagation to adaptive learning algorithms, **Computer Standards & Interfaces**, v. 16, n. 3, p. 265–278, 1994.

Rodrigues, D. D. **Previsão de fornecimento de energia elétrica: Um estudo de caso do ponto de vista do barramento**. Tese de Doutorado. Universidade Federal de Minas Gerais, Brasil, Belo Horizonte, 2002.

Romera, G. E.; Moran, M. A. J.; Fernandez, D. C. Forecasting of the Electric Energy Demand Trend and Monthly Fluctuation with Neural Networks. **Computers & Industrial Engineering**, v. 52. p. 336-343, 2007.

Rosenblatt, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychol. Rev.**, v. 65, p. 386-408, 1958.

Rumelhart, D. E.; Hinton G. E.; Williams, R. J. Learning representations by backpropagation errors. **Nature**, v. 323, p. 533-536, 1986.

Serrão, F.C.C. **Modelo de previsão de carga de curto prazo utilizando redes neurais e lógica fuzzy**. Tese de Doutorado. Pontifica Universidade Católica, Brasil, Rio de Janeiro, 2003.

Silva, I. D.; Spatti, D. H.; Flauzino, R. A. **Redes neurais artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, p. 33-111, 2010.

Sombra, S. S. Modelagem numérica em alta resolução para previsão de geração de energia eólica no Ceará. **Revista Brasileira de Meteorologia**, v. 23, n. 4, p. 477-489, 2008.

Soytas, U.; Sari, R. Energy consumption, economic growth, and carbon emissions: challenges faced by an EU candidate member. **Ecological economics**, v. 68, n. 6, p. 1667-1675, 2009.

Thoma, M. Electrical energy usage over the business cycle. **Energy Economics**, v. 26, n. 3, p. 463-485, 2004.

Tidre, P. V. V.; Biase, N. G. G.; Silva, M. I S. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica da região Norte do Brasil. **Matemática e Estatística em Foco**, v. 1, n. 1, p. 57-66, 2013.

Tripathi, M. M.; Upadhyay, K. G.; Singh, S. N. Short-term load forecasting using generalized regression and probabilistic neural networks in the electricity market. **The Electricity Journal**, v. 21, n. 9, p. 24-34, 2008.

Uzlu, E.; Akpınar, A.; Öztürk, H. T.; Nacar, S.; Kankal, M. Estimates of hydroelectric generation using neural networks with the artificial bee colony algorithm for Turkey. **Energy**, v. 69, p. 638-647, 2014.

Wasserman, P. D. **Advanced methods in neural computing**. New York: Van Nostrand Reinhold, 1989.

Wolde-Rufael, Yemane. Electricity consumption and economic growth: a time series experience for 17 African countries. **Energy policy**, v. 34, n. 10, p. 1106-1114, 2006.

Yap, K. S.; Abidin, I. Z.; Lim, C. P.; Shah, M. S. Short Term Load Forecasting Using a Hybrid Neural Network, **First International Power and Energy Conference (PECon)**, p. 123-128, 2006.

Yona, A., Senjyu, T., Saber, A. Y.; Funabashi, T.; Sekine, H.; Kim, C. H. Application of neural network to one-day-ahead 24 hours generating power forecasting for photovoltaic system. **In Intelligent Systems Applications to Power Systems, 2007. ISAP 2007. International Conference on**. IEEE. p. 1-6, 2007.

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA)**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |          |          |          |          |          |          |          |          |
|--|----------|----------|----------|----------|----------|----------|----------|----------|
| ANO  | 2009     | 2009     | 2009     | 2009     | 2009     | 2009     | 2009     | 2009     |
| MÊS  | 1        | 2        | 3        | 4        | 5        | 6        | 7        | 8        |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,77518  | 0,716373 | 0,698497 | 0,635014 | 0,552382 | 0,548693 | 0,810186 | 0,820004 |
| % DA GERAÇÃO TÉRMICA                                       | 0,180146 | 0,246779 | 0,25532  | 0,331474 | 0,404787 | 0,393154 | 0,140307 | 0,1495   |
| % DA GERAÇÃO EÓLICA  | 0,044674 | 0,036847 | 0,046183 | 0,033511 | 0,042831 | 0,058153 | 0,049507 | 0,030496 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2358,14  | 2448,67  | 2417,34  | 2371,46  | 2228,46  | 2042,35  | 2263,82  | 1891,2   |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 12,74    | 17,76    | 21,47    | 22,41    | 2,7      | 228,99   | 13,28    | 99,25    |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0        | 0        | 0        | 0        | 0        | 0        | 0        | 0        |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 9,59     | 9,47     | 0,37     | 15,33    | 0,24     | 2,6      | 1,54     | 21,07    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3307,52  | 3466,3   | 3435,06  | 3231,92  | 3046,89  | 2566,52  | 3147,46  | 3104,19  |
| ICMS (R\$ mil) - DADOS IPEA                                | 1342779  | 1111070  | 1116238  | 1282456  | 1249666  | 1196963  | 1176311  | 1214494  |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,48     | 0,55     | 0,2      | 0,48     | 0,47     | 0,36     | 0,24     | 0,15     |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | -0,44    | 0,26     | -0,74    | -0,15    | -0,07    | -0,1     | -0,43    | -0,36    |
| DIREÇÃO DO VENTO   | 12,66667 | 8,25     | 13,81818 | 11,72727 | 13,91667 | 11,58333 | 9,666667 | 13       |
| VELOCIDADE DO VENTO (m/s)                                  | 2,715681 | 2,282143 | 2,164803 | 2,0825   | 1,98414  | 2,139722 | 2,125347 | 2,649642 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 152,575  | 156,4583 | 86,25    | 26,975   | 116,1667 | 67,225   | 89,45833 | 188,025  |
| PRESSÃO MÉDIA (mbar)                                       | 950,3215 | 957,1786 | 950,6061 | 961,5419 | 961,9068 | 969,8051 | 954,7606 | 961,2194 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 28,0372  | 28,71042 | 27,88172 | 26,07583 | 22,34274 | 17,12889 | 16,18475 | 21,32796 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 17,53011 | 18,83095 | 17,83441 | 14,16528 | 11,80618 | 7,191389 | 6,135484 | 10,54731 |
| UMIDADE RELATIVA (%)                                       | 72,58938 | 75,58408 | 76,77957 | 72,18053 | 78,50202 | 80,35486 | 78,14315 | 76,17944 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 971,71   | 1044,86  | 1039,56  | 898,2    | 821,37   | 755,76   | 898,46   | 1333,31  |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |          |          |          |          |          |          |          |          |
|--|----------|----------|----------|----------|----------|----------|----------|----------|
| ANO  | 2009     | 2009     | 2009     | 2009     | 2010     | 2010     | 2010     | 2010     |
| MÊS  | 9        | 10       | 11       | 12       | 1        | 2        | 3        | 4        |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,887083 | 0,915916 | 0,917831 | 0,923109 | 0,904807 | 0,875154 | 0,84599  | 0,820708 |
| % DA GERAÇÃO TÉRMICA                                       | 0,081224 | 0,052351 | 0,050361 | 0,048437 | 0,072501 | 0,103421 | 0,120688 | 0,155594 |
| % DA GERAÇÃO EÓLICA  | 0,031693 | 0,031732 | 0,031808 | 0,028454 | 0,022693 | 0,021425 | 0,033322 | 0,023698 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 1709,02  | 1648,72  | 1891,79  | 1865,84  | 2204,69  | 2577,79  | 2636,62  | 2475,4   |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 222,93   | 217,48   | 156,44   | 131,05   | 69,41    | 47,62    | 20,91    | 24,13    |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0        | 9,21     | 1,82     | 1,72     | 0        | 0        | 0        | 0        |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 15,2     | 0,21     | 0,87     | 0,57     | 0,34     | 0,29     | 0,19     | 0,64     |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3075,34  | 3112,03  | 3302,59  | 3420,41  | 3645,13  | 3833,97  | 3728,89  | 3357,03  |
| ICMS (R\$ mil) - DADOS IPEA                                | 1243154  | 1308755  | 1419094  | 1425691  | 1541029  | 1144848  | 1421601  | 1534248  |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,24     | 0,28     | 0,41     | 0,37     | 0,75     | 0,78     | 0,52     | 0,57     |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 0,42     | 0,05     | 0,1      | -0,26    | 0,63     | 1,18     | 0,94     | 0,77     |
| DIREÇÃO DO VENTO   | 12,75    | 13,83333 | 12       | 13,16667 | 12,66667 | 10,16667 | 10,75    | 10,16667 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,833241 | 2,809409 | 2,637963 | 2,732348 | 2,352957 | 2,509127 | 2,185125 | 2,224895 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 327,6667 | 125,8    | 401,6167 | 188,275  | 237,825  | 197,2417 | 83,575   | 126,6083 |
| PRESSÃO MÉDIA (mbar)                                       | 967,0368 | 950,7882 | 959,876  | 956,2381 | 956,5025 | 956,8859 | 950,6608 | 954,1383 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 19,79361 | 23,66344 | 27,02028 | 27,78468 | 28,82554 | 29,7747  | 27,72688 | 24,22361 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 11,41833 | 12,77312 | 18,16194 | 18,08226 | 19,26237 | 20,18958 | 17,84409 | 14,04139 |
| UMIDADE RELATIVA (%)                                       | 82,65694 | 75,28024 | 82,56458 | 77,83938 | 79,47379 | 78,51042 | 77,96169 | 76,92083 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1604,45  | 1671,79  | 1566,29  | 1684,47  | 1510,19  | 1304,09  | 1113,37  | 906,4    |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2010    | 2010    | 2010    | 2010    | 2010    | 2010    | 2010    | 2010    |
| MÊS  | 5       | 6       | 7       | 8       | 9       | 10      | 11      | 12      |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,83523 | 0,8439  | 0,91003 | 0,75236 | 0,80214 | 0,88396 | 0,77112 | 0,83352 |
| % DA GERAÇÃO TÉRMICA                                       | 0,13355 | 0,12185 | 0,05502 | 0,21616 | 0,15496 | 0,08989 | 0,19729 | 0,13126 |
| % DA GERAÇÃO EÓLICA  | 0,03121 | 0,03425 | 0,03495 | 0,03148 | 0,0429  | 0,02615 | 0,03159 | 0,03522 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2064,92 | 1974,5  | 1960,14 | 1972,8  | 1771,07 | 1915,45 | 2034,69 | 2138,78 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 50,31   | 38,94   | 70,62   | 67,48   | 131,14  | 100,59  | 26,57   | 44,98   |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 4,6     | 0,43    | 19,74   | 0,24    | 0,25    | 0,25    | 0,26    | 0,34    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3255,72 | 3292,41 | 3349,77 | 3286,54 | 3202,01 | 3157,46 | 3307,03 | 3376,38 |
| ICMS (R\$ mil) - DADOS IPEA                                | 1452966 | 1396593 | 1456078 | 1727219 | 1542507 | 1491497 | 1580380 | 1625469 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,43    | 0       | 0,01    | 0,04    | 0,45    | 0,75    | 0,83    | 0,63    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 1,19    | 0,85    | 0,15    | 0,77    | 1,15    | 1,01    | 1,45    | 0,69    |
| DIREÇÃO DO VENTO   | 8,5     | 8,66667 | 10,9167 | 13,5    | 12,4167 | 14,9167 | 14,5    | 9,33333 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,27805 | 2,39731 | 2,45789 | 2,48835 | 2,7862  | 2,51335 | 2,52472 | 2,7129  |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 154,708 | 101,808 | 200,767 | 54,2667 | 188,775 | 65,8417 | 76,4    | 104,483 |
| PRESSÃO MÉDIA (mbar)                                       | 963,083 | 963,016 | 970,182 | 955,982 | 952,685 | 952,134 | 958,202 | 960,132 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 19,7739 | 18,7303 | 18,5726 | 18,6594 | 20,9914 | 22,7363 | 26,1689 | 28,5653 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 11,9801 | 9,60722 | 8,5043  | 9,09866 | 12,1053 | 12,1535 | 14,2458 | 17,4707 |
| UMIDADE RELATIVA (%)                                       | 85,0249 | 81,459  | 79,5121 | 77,3522 | 78,6431 | 71,6317 | 67,3444 | 69,0592 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1245,71 | 1357,28 | 1479,99 | 1381,46 | 1562,33 | 1342,85 | 1299,17 | 1282,92 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2011    | 2011    | 2011    | 2011    | 2011    | 2011    | 2011    | 2011    |
| MÊS  | 1       | 2       | 3       | 4       | 5       | 6       | 7       | 8       |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,74252 | 0,74354 | 0,82409 | 0,79768 | 0,83373 | 0,80986 | 0,8429  | 0,83679 |
| % DA GERAÇÃO TÉRMICA                                       | 0,23772 | 0,23992 | 0,12511 | 0,18549 | 0,14048 | 0,15398 | 0,1098  | 0,09561 |
| % DA GERAÇÃO EÓLICA  | 0,01977 | 0,01654 | 0,0508  | 0,01683 | 0,02579 | 0,03616 | 0,0473  | 0,0676  |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2793,83 | 2666,77 | 2753,36 | 2168,5  | 2126,24 | 2002,96 | 1801,1  | 1714    |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 91,65   | 101,36  | 97,05   | 136,03  | 95,99   | 81,06   | 179,75  | 216,65  |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0,48    | 11,78   | 16,9    | 25,66   | 50,24   | 54,52   | 5,86    | 0,2     |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 4053,06 | 4004,83 | 3766,91 | 3457,02 | 3430,38 | 3478,22 | 3549,26 | 3524,28 |
| ICMS (R\$ mil) - DADOS IPEA                                | 1664506 | 1434280 | 1455132 | 1642541 | 1539683 | 1524884 | 1582319 | 1685540 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,83    | 0,8     | 0,79    | 0,77    | 0,47    | 0,15    | 0,16    | 0,37    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 0,79    | 1       | 0,62    | 0,45    | 0,43    | -0,18   | -0,12   | 0,44    |
| DIREÇÃO DO VENTO   | 13,4167 | 11,25   | 10,9167 | 11,6667 | 12,4167 | 15,75   | 10,8333 | 10,0833 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,36201 | 2,55526 | 2,78378 | 1,91241 | 2,25573 | 2,33343 | 2,36505 | 3,1578  |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 141,142 | 164,158 | 169,292 | 132,075 | 83,5583 | 142,442 | 202,992 | 192,975 |
| PRESSÃO MÉDIA (mbar)                                       | 960,506 | 968,731 | 960,675 | 952,604 | 962,659 | 962,019 | 963,342 | 962,207 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 30,3306 | 28,356  | 27,0898 | 25,0792 | 20,3823 | 17,4559 | 17,1443 | 18,4925 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 20,1683 | 19,5387 | 16,7266 | 14,4108 | 11,2823 | 8,58693 | 8,4846  | 9,37177 |
| UMIDADE RELATIVA (%)                                       | 76,6794 | 80,4561 | 75,7567 | 77,4986 | 81,4819 | 81,9201 | 81,3656 | 79,3091 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1351,36 | 1451,2  | 1127,5  | 1450,21 | 1450,37 | 1610,84 | 1933,77 | 2027,13 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2011    | 2011    | 2011    | 2011    | 2012    | 2012    | 2012    | 2012    |
| MÊS  | 9       | 10      | 11      | 12      | 1       | 2       | 3       | 4       |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,8605  | 0,79706 | 0,64413 | 0,62974 | 0,61107 | 0,62632 | 0,56147 | 0,46629 |
| % DA GERAÇÃO TÉRMICA                                       | 0,06806 | 0,12675 | 0,25646 | 0,27345 | 0,30174 | 0,30532 | 0,36287 | 0,44302 |
| % DA GERAÇÃO EÓLICA  | 0,07145 | 0,0762  | 0,09941 | 0,09681 | 0,08719 | 0,06836 | 0,07565 | 0,09068 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 1965,24 | 2141,18 | 2422,58 | 2729,6  | 2936,48 | 3172,35 | 2989,29 | 2568,03 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 85,57   | 60,88   | 38,69   | 1,76    | 8,39    | 33,74   | 18,09   | 1,73    |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 14,4    | 23,79   | 55,78   | 25,03   | 35,74   | 52,58   | 58,14   | 17,34   |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3367,82 | 3396,99 | 3622,47 | 3822,68 | 4064,42 | 4265,42 | 4032,95 | 3548,48 |
| ICMS (R\$ mil) - DADOS IPEA                                | 1636917 | 1720892 | 1793228 | 1823006 | 1852165 | 1409620 | 1765030 | 1786275 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,53    | 0,43    | 0,52    | 0,5     | 0,56    | 0,45    | 0,21    | 0,64    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 0,65    | 0,53    | 0,5     | -0,12   | 0,25    | -0,06   | 0,43    | 0,85    |
| DIREÇÃO DO VENTO   | 9,66667 | 10,0833 | 8,91667 | 13,8333 | 12      | 16,1667 | 14,9167 | 13,8333 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,75648 | 2,74167 | 2,94778 | 2,69695 | 2,88934 | 2,36753 | 2,16792 | 2,15685 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 76,575  | 146,017 | 45,9917 | 77,8333 | 100,867 | 132,867 | 81,0583 | 91,675  |
| PRESSÃO MÉDIA (mbar)                                       | 955,394 | 950,719 | 951,12  | 962,65  | 956,829 | 956,863 | 952,019 | 961,213 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 21,8772 | 23,7406 | 26,9644 | 27,5874 | 29,7293 | 30,6178 | 28,2296 | 24,0378 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 10,415  | 13,5739 | 15,1412 | 16,3102 | 18,2403 | 20,0434 | 16,6223 | 13,7947 |
| UMIDADE RELATIVA (%)                                       | 72,6083 | 74,7493 | 67,5306 | 67,6862 | 68,1848 | 73,6106 | 69,8636 | 75,3221 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1502,55 | 1340,48 | 1294,36 | 1119,87 | 1172,07 | 1179,39 | 1119,89 | 999,52  |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2012    | 2012    | 2012    | 2012    | 2012    | 2012    | 2012    | 2012    |
| MÊS  | 5       | 6       | 7       | 8       | 9       | 10      | 11      | 12      |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,24937 | 0,30338 | 0,59839 | 0,45629 | 0,6253  | 0,65652 | 0,5803  | 0,65329 |
| % DA GERAÇÃO TÉRMICA                                       | 0,62414 | 0,56936 | 0,2845  | 0,40041 | 0,25423 | 0,25277 | 0,32528 | 0,25686 |
| % DA GERAÇÃO EÓLICA  | 0,12649 | 0,12726 | 0,11712 | 0,1433  | 0,12048 | 0,09071 | 0,09442 | 0,08985 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2865,75 | 2903,67 | 2660,75 | 2623,08 | 2057,73 | 1734,57 | 2349,45 | 2363,87 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 0       | 0       | 0       | 0       | 14,62   | 60,3    | 23,9    | 29,42   |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 63,62   | 67,04   | 57,35   | 55,45   | 60,46   | 12,45   | 0,17    | 0,23    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3513    | 3544,56 | 3604,29 | 3585,86 | 3387,73 | 3511,65 | 3835,98 | 3866,01 |
| ICMS (R\$ mil) - DADOS IPEA                                | 1708771 | 1685412 | 1786297 | 1600097 | 1740615 | 1889474 | 2159713 | 1994739 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,36    | 0,08    | 0,43    | 0,41    | 0,57    | 0,59    | 0,6     | 0,79    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 1,02    | 0,66    | 1,34    | 1,43    | 0,97    | 0,02    | -0,03   | 0,68    |
| DIREÇÃO DO VENTO   | 9,33333 | 15,3333 | 13,8333 | 9,41667 | 10,5    | 9,41667 | 11,5833 | 15,0833 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,12384 | 2,0391  | 2,44992 | 2,87285 | 3,07981 | 2,79274 | 2,75139 | 2,64211 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 35,6917 | 80,6083 | 129,383 | 90,6083 | 178,033 | 224,125 | 51,1667 | 231,967 |
| PRESSÃO MÉDIA (mbar)                                       | 963,513 | 961,743 | 954,865 | 956,507 | 954,087 | 950,524 | 950,416 | 960,643 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 23,1282 | 18,9028 | 17,1809 | 23,0161 | 22,3153 | 24,3196 | 28,0128 | 29,3688 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 12,2688 | 9,32639 | 7,28737 | 13,0247 | 12,3917 | 15,482  | 16,5617 | 18,8798 |
| UMIDADE RELATIVA (%)                                       | 75,6573 | 79,2493 | 77,5874 | 75,1354 | 74,0229 | 77,7957 | 66,7215 | 73,584  |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 710,87  | 707,93  | 1000,89 | 1018,23 | 1405,08 | 1849,83 | 1510,6  | 1531,79 |



**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2013    | 2013    | 2013    | 2013    | 2013    | 2013    | 2013    | 2013    |
| MÊS  | 1       | 2       | 3       | 4       | 5       | 6       | 7       | 8       |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,55622 | 0,59829 | 0,61896 | 0,60384 | 0,56165 | 0,64284 | 0,6531  | 0,72061 |
| % DA GERAÇÃO TÉRMICA                                       | 0,37064 | 0,33807 | 0,314   | 0,30739 | 0,37009 | 0,27471 | 0,26698 | 0,19278 |
| % DA GERAÇÃO EÓLICA  | 0,07314 | 0,06364 | 0,06704 | 0,08877 | 0,06826 | 0,08245 | 0,07992 | 0,08661 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2193,53 | 2284,02 | 1707,37 | 2161,94 | 2071,71 | 2220,3  | 2353,81 | 2020,21 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 36,01   | 42,07   | 99,09   | 33,46   | 37,5    | 25,72   | 18,23   | 67,05   |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0,21    | 0,41    | 0,18    | 0,12    | 0,29    | 0,16    | 0,21    | 0,22    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 4058,74 | 4025,67 | 3559,83 | 3768,26 | 3630,27 | 3627,67 | 3735,45 | 3742,29 |
| ICMS (R\$ mil) - DADOS IPEA                                | 2012638 | 1833498 | 1719414 | 1991434 | 1998896 | 1950880 | 1943341 | 2022132 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,86    | 0,6     | 0,47    | 0,55    | 0,37    | 0,26    | 0,03    | 0,24    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 0,34    | 0,29    | 0,21    | 0,15    | 0       | 0,75    | 0,26    | 0,15    |
| DIREÇÃO DO VENTO   | 12      | 13,5    | 14,5833 | 9,33333 | 16,5    | 14,6667 | 14,3333 | 12,3333 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,6629  | 2,53917 | 2,48656 | 2,15626 | 2,08486 | 2,06222 | 2,18566 | 2,59247 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 136,8   | 163,6   | 149,967 | 119,383 | 104,617 | 96,4167 | 91,45   | 226,475 |
| PRESSÃO MÉDIA (mbar)                                       | 958,704 | 957,412 | 952,302 | 953,408 | 953,378 | 961,856 | 965,156 | 971,354 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 28,1247 | 28,1432 | 24,875  | 24,6403 | 20,3973 | 18,1886 | 18,4434 | 17,9328 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 17,3863 | 18,5027 | 15,5884 | 13,9631 | 11,104  | 9,74056 | 8,24415 | 7,94409 |
| UMIDADE RELATIVA (%)                                       | 70,623  | 77,1838 | 77,7957 | 75,9333 | 80,6358 | 84,6877 | 79,3737 | 78,121  |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1901,43 | 1784,13 | 1951,73 | 1639,9  | 1596,35 | 1433,25 | 1400,08 | 1789,35 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2013    | 2013    | 2013    | 2013    | 2014    | 2014    | 2014    | 2014    |
| MÊS  | 9       | 10      | 11      | 12      | 1       | 2       | 3       | 4       |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,77218 | 0,69992 | 0,68588 | 0,75123 | 0,74608 | 0,58617 | 0,66247 | 0,59559 |
| % DA GERAÇÃO TÉRMICA                                       | 0,15172 | 0,19713 | 0,19465 | 0,1327  | 0,19034 | 0,3375  | 0,26085 | 0,32709 |
| % DA GERAÇÃO EÓLICA  | 0,0761  | 0,10295 | 0,11947 | 0,11607 | 0,06358 | 0,07633 | 0,07668 | 0,07732 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 1680,59 | 1972,81 | 2061,27 | 2792,9  | 2889,66 | 2852,16 | 1936,57 | 1769,63 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 171,17  | 92,06   | 88,48   | 18,88   | 42,07   | 46,28   | 75,35   | 100,9   |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0,17    | 0,2     | 0,1     | 0,23    | 0,37    | 0,42    | 0,24    | 0,19    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3571,07 | 3643,68 | 3873,2  | 4196,21 | 4574,66 | 4759,14 | 3801,59 | 3803,57 |
| ICMS (R\$ mil) - DADOS IPEA                                | 2052272 | 2112672 | 2276685 | 2146702 | 2206733 | 2045248 | 1975407 | 2111810 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,35    | 0,57    | 0,54    | 0,92    | 0,55    | 0,69    | 0,92    | 0,67    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | 1,5     | 0,86    | 0,29    | 0,6     | 0,48    | 0,38    | 1,67    | 0,78    |
| DIREÇÃO DO VENTO   | 10,5    | 10,5    | 10,5    | 10,5    | 16,1    | 13,4    | 9,4     | 11,2    |
| VELOCIDADE DO VENTO (m/s)                                  | 2,69019 | 2,73072 | 3,16    | 2,59586 | 2,59255 | 2,77083 | 2,40892 | 2,43067 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 140,933 | 139,442 | 206,767 | 95,875  | 182,94  | 212,61  | 194,4   | 92,94   |
| PRESSÃO MÉDIA (mbar)                                       | 961,949 | 966,962 | 950,269 | 955,669 | 945,907 | 946,446 | 946,804 | 971,713 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 21,3655 | 23,7575 | 26,6844 | 29,8374 | 30,6252 | 30,1846 | 26,6207 | 24,4977 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 11,5819 | 13,3271 | 16,0144 | 18,4855 | 20,3719 | 20,1921 | 16,96   | 15,416  |
| UMIDADE RELATIVA (%)                                       | 76,3778 | 73,6365 | 71,8271 | 69,5638 | 73,5185 | 74,383  | 77,6726 | 78,1392 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 2061,82 | 1763,13 | 1900,51 | 1422,42 | 1727,44 | 1953,68 | 1940,61 | 2135,03 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|--|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO  | 2014    | 2014    | 2014    | 2014    | 2014    | 2014    | 2014    | 2014    |
| MÊS  | 5       | 6       | 7       | 8       | 9       | 10      | 11      | 12      |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,59326 | 0,71399 | 0,74845 | 0,67477 | 0,7078  | 0,683   | 0,68219 | 0,72427 |
| % DA GERAÇÃO TÉRMICA                                       | 0,33999 | 0,18607 | 0,15909 | 0,23543 | 0,20147 | 0,21714 | 0,22261 | 0,17076 |
| % DA GERAÇÃO EÓLICA  | 0,06675 | 0,09994 | 0,09246 | 0,08979 | 0,09074 | 0,09986 | 0,0952  | 0,10497 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 1870,32 | 1724    | 1647,15 | 1565,19 | 1325,62 | 1483,36 | 1882,91 | 2293,17 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 115,36  | 149,82  | 342,22  | 182,7   | 327,67  | 277,57  | 141,36  | 151,65  |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0,21    | 0,24    | 0,25    | 0,31    | 0,33    | 0,31    | 0,25    | 0,35    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 3681,62 | 3664,05 | 3714,38 | 3661,75 | 3579,06 | 3774,47 | 3969,71 | 3953,06 |
| ICMS (R\$ mil) - DADOS IPEA                                | 2046364 | 2096162 | 1869931 | 2107171 | 2301561 | 2228441 | 2367089 | 2498295 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 0,46    | 0,4     | 0,01    | 0,25    | 0,57    | 0,42    | 0,51    | 0,78    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                      | -0,13   | -0,74   | -0,61   | -0,27   | 0,2     | 0,28    | 0,98    | 0,62    |
| DIREÇÃO DO VENTO   | 11,6    | 11,2    | 9,4     | 12,1    | 14,4    | 9       | 11,6    | 12,1    |
| VELOCIDADE DO VENTO (m/s)                                  | 2,00892 | 2,38267 | 2,42376 | 2,4471  | 2,91933 | 2,87634 | 2,57822 | 2,49914 |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 137,52  | 220,94  | 168,57  | 86,29   | 196,69  | 211,28  | 95,6    | 241,26  |
| PRESSÃO MÉDIA (mbar)                                       | 949,121 | 949,13  | 951,827 | 950,283 | 947,282 | 948,055 | 972,639 | 962,3   |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 20,4974 | 18,2137 | 19,5126 | 21,65   | 22,24   | 25,634  | 27,3467 | 28,0619 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 11,8468 | 10,4733 | 10,3029 | 10,3968 | 13,5247 | 15,909  | 16,896  | 18,5048 |
| UMIDADE RELATIVA (%)                                       | 83,4798 | 85,5133 | 81,4992 | 74,7516 | 81,0883 | 76,1419 | 70,3925 | 75,0282 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 1926,87 | 2090,11 | 2409,7  | 2279,57 | 2581,44 | 2568,99 | 2228,41 | 1811,89 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NO TREINAMENTO DA RNA – MATRIZ DE ENTRADA |         |         |         |
|--|---------|---------|---------|
| ANO  | 2015    | 2015    | 2015    |
| MÊS  | 1       | 2       | 3       |
| % DA GERAÇÃO HIDRÁULICA                                    | 0,71037 | 0,61352 | 0,45791 |
| % DA GERAÇÃO TÉRMICA                                       | 0,21137 | 0,28252 | 0,41143 |
| % DA GERAÇÃO EÓLICA  | 0,07826 | 0,10397 | 0,13066 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 2314,36 | 2135,74 | 2064,85 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                     | 83,51   | 144,12  | 90,98   |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)             | 0,26    | 0,35    | 0,2     |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)        | 4503,67 | 4429,56 | 4260,17 |
| ICMS (R\$ mil) - DADOS IPEA                                | 2363242 | 2088685 | 2071385 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                      | 1,24    | 1,22    | 1,32    |
| INFLAÇÃO - IGP-M (% a.m.) - DADOS IPEA                     | 0,76    | 0,27    | 0,98    |
| DIREÇÃO DO VENTO   | 10,3    | 10,3333 | 12,3333 |
| VELOCIDADE DO VENTO (m/s)                                  | 2,20524 | 2,06852 | 2,0172  |
| PRECIPITAÇÃO MÉDIA (mm)                                    | 211,09  | 113,089 | 90,5333 |
| PRESSÃO MÉDIA (mbar)                                       | 963,946 | 963,53  | 947,288 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                              | 29,3682 | 28,8992 | 28,1237 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                              | 19,8398 | 19,2627 | 17,9692 |
| UMIDADE RELATIVA (%)                                       | 77,9725 | 78,2639 | 76,31   |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)              | 2273,08 | 2438,29 | 2286,5  |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NA PREVISÃO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |         |         |         |         |
|---|---------|---------|---------|---------|---------|---------|---------|---------|
| ANO   | 2015    | 2015    | 2015    | 2015    | 2015    | 2015    | 2015    | 2015    |
| MÊS   | 4       | 5       | 6       | 7       | 8       | 9       | 10      | 11      |
| % DA GERAÇÃO HIDRÁULICA                                 | 0,50296 | 0,51829 | 0,62791 | 0,69065 | 0,61513 | 0,64842 | 0,65781 | 0,70751 |
| % DA GERAÇÃO TÉRMICA                                    | 0,36124 | 0,31293 | 0,20931 | 0,166   | 0,15875 | 0,15379 | 0,13469 | 0,07317 |
| % DA GERAÇÃO EÓLICA                                     | 0,13579 | 0,16877 | 0,16279 | 0,14334 | 0,22611 | 0,19779 | 0,2075  | 0,21932 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                  | 1659,54 | 1562,3  | 1411,25 | 1435,53 | 1365,07 | 1406,63 | 1025,22 | 1425,81 |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                  | 61,88   | 38,71   | 78,47   | 278,53  | 273,96  | 144,48  | 359,81  | 253,73  |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)          | 0       | 0       | 0       | 0       | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)          | 0,2     | 0,13    | 0,3     | 0,42    | 0,4     | 0,37    | 0,38    | 0,32    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)     | 3682,61 | 3508,96 | 3535    | 3561,77 | 3485,47 | 3367,02 | 3357,42 | 3387,02 |
| ICMS (R\$ mil) - DADOS IPEA                             | 2340603 | 2217941 | 2193441 | 2124310 | 2129923 | 2524577 | 2292923 | 2391677 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                   | 0,71    | 0,74    | 0,79    | 0,62    | 0,22    | 0,54    | 0,82    | 1,01    |
| INFLAÇÃO - IGP-M (%a.m.) - DADOS IPEA                   | 1,17    | 0,41    | 0,67    | 0,69    | 0,28    | 0,95    | 1,89    | 1,52    |
| DIREÇÃO DO VENTO  | 9,77778 | 11,3333 | 19,3333 | 16,3333 | 13,4444 | 11,3333 | 11,8889 | 11,3333 |
| VELOCIDADE DO VENTO (m/s)                               | 1,79395 | 1,89845 | 1,91056 | 1,94688 | 2,56295 | 2,28126 | 2,51327 | 2,52316 |
| PRECIPITAÇÃO MÉDIA (mm)                                 | 116,244 | 161,633 | 162,444 | 237,578 | 99,4333 | 205,489 | 327,167 | 174,478 |
| PRESSÃO MÉDIA (mbar)                                    | 948,838 | 949,969 | 962,227 | 949,672 | 948,442 | 946,347 | 947,082 | 954,249 |
| TEMPERATURA MÁXIMA MÉDIA (°C)                           | 25,6111 | 21,7043 | 19,9315 | 18,7889 | 24,0932 | 22,097  | 22,9921 | 24,8385 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                           | 14,9944 | 13,0269 | 10,5296 | 11,0267 | 14,8097 | 12,5474 | 14,3319 | 16,0793 |
| UMIDADE RELATIVA (%)                                    | 75,8759 | 82,1147 | 80,913  | 85,75   | 74,5744 | 76,65   | 80,8351 | 78,0574 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)           | 2085,15 | 1985,5  | 2202,52 | 2405,19 | 2394,76 | 2105,24 | 2692,39 | 2215,26 |

**ANEXO A - Tabela A.1 - Banco de dados (Matriz de entrada e matriz alvo da RNA) - Continuação**

| DADOS UTILIZADOS NA PREVISÃO DA RNA – MATRIZ DE ENTRADA |         |         |         |         |
|---|---------|---------|---------|---------|
| ANO   | 2015    | 2016    | 2016    | 2016    |
| MÊS   | 12      | 1       | 2       | 3       |
| % DA GERAÇÃO HIDRÁULICA                                 | 0,75795 | 0,6372  | 0,64709 | 0,6094  |
| % DA GERAÇÃO TÉRMICA                                    | 0,07537 | 0,12326 | 0,16199 | 0,17237 |
| % DA GERAÇÃO EÓLICA                                     | 0,16668 | 0,23954 | 0,19092 | 0,21823 |
| IMPORTAÇÃO DE ENERGIA - SIN (MW médio)                  | 1450,07 | 2202,52 | 2436,06 | 1738    |
| EXPORTAÇÃO DE ENERGIA - SIN (MW médio)                  | 295,06  | 130,15  | 137,59  | 128,86  |
| IMPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)          | 0       | 0       | 0       | 0       |
| EXPORTAÇÃO INTERNACIONAL DE ENERGIA (MW médio)          | 0,41    | 0,38    | 0,35    | 0,31    |
| CARGA PRÓPRIA DE ENERGIA NO ESTADO DO RS (MW médio)     | 3602,46 | 4252,53 | 4399,95 | 3866,86 |
| ICMS (R\$ mil) - DADOS IPEA                             | 2387185 | 2474394 | 2489680 | 2442548 |
| INFLAÇÃO - IPCA (% a.m.) - DADOS IPEA                   | 0,96    | 1,27    | 0,9     | 0,43    |
| INFLAÇÃO - IGP-M (% a.m.) - DADOS IPEA                  | 0,49    | 1,14    | 1,29    | 0,51    |
| DIREÇÃO DO VENTO  | 11,8889 | 10,2222 | 7,44444 | 15,3333 |
| VELOCIDADE DO VENTO (m/s)                               | 2,2458  | 2,11652 | 1,86866 | 2,11699 |
| PRECIPITAÇÃO MÉDIA (mm)                                 | 308,822 | 118,5   | 147,578 | 215,044 |
| PRESSÃO MÉDIA (mbar)                                    | 953,895 | 961,557 | 955,92  | 959,1   |
| TEMPERATURA MÁXIMA MÉDIA (°C)                           | 27,571  | 30,0588 | 29,9674 | 26,2287 |
| TEMPERATURA MÍNIMA MÉDIA (°C)                           | 18,9748 | 19,9358 | 20,3962 | 17,2305 |
| UMIDADE RELATIVA (%)                                    | 80,0063 | 72,9211 | 78,0517 | 79,7428 |
| ALVO - GERAÇÃO DE ENERGIA ELÉTRICA (MW médio)           | 2447,86 | 2180,54 | 2101,83 | 2258,03 |